



TECHNICKÁ UNIVERZITA V LIBERCI
Fakulta textilní



REKONSTRUKCE A IDENTIFIKACE VAZBY TKANINY POMOCÍ OBRAZOVÉ ANALÝZY

Diplomová práce

Studijní program: N3957 – Průmyslové inženýrství
Studijní obor: 3901T073 – Produktové inženýrství
Autor práce: **Tereza Daňková**
Vedoucí práce: doc. Ing. Maroš Tunák, Ph.D.





TECHNICAL UNIVERSITY OF LIBEREC
Faculty of Textile Engineering



REVERSE RECONSTRUCTION AND IDENTIFICATION OF WEAVE PATTERNS BY IMAGE ANALYSIS

Diploma thesis

Study programme: N3957 – Industrial Engineering
Study branch: 3901T073 – Product Engineering
Author: **Tereza Daňková**
Supervisor: doc. Ing. Maroš Tunák, Ph.D.



ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Tereza Daňková**
Osobní číslo: **T12000448**
Studijní program: **N3957 Průmyslové inženýrství**
Studijní obor: **Produktové inženýrství**
Název tématu: **Rekonstrukce a identifikace vazby tkaniny pomocí obrazové analýzy**
Zadávací katedra: **Katedra hodnocení textilií**

Z á s a d y p r o v y p r a c o v á n í :

- (1) Vypracujte rešerši týkající se zpětné rekonstrukce vazby tkaniny s využitím nástrojů obrazové analýzy.
- (2) Vytvořte sadu obrazů reprezentativních vzorovaných tkanin.
- (3) Navrhněte postup a vytvořte algoritmus v MatLabu pro zpětnou rekonstrukci vazby tkaniny.
- (4) Aplikujte zkoumaný postup na sadě obrazů reprezentativních vzorovaných tkanin.

Rozsah grafických prací:

Rozsah pracovní zprávy: 50 - 60 stran

Forma zpracování diplomové práce: tištěná/elektronická

Seznam odborné literatury:

- [1] PING Z, TAO Y, YUNLONG S AND XINXING T. Research on Computer-aided Analysis and Reverse Reconstruction for the Weave Pattern of Fabric. Textile Research Journal 83(3), 298-310, 2013.
- [2] ZHENG D, HAN Y AND HU J. A New Method for Classification of Woven Structure for Yarn-Dyed Fabric. Textile Research Journal 84(1), 78-95, 2013.
- [3] JEONG Y, JANG J. Applying Image Analysis to Automatic Inspection of Fabric Density for Woven Fabrics, Fibers Polym. 6(2), 156-161, 2005.
- [4] GONZALEZ RC, WOOD RE AND EDDINS SL. Digital Image Processing using MatLab. 2nd edition, Prentice-Hall, 2002.

Vedoucí diplomové práce:

doc. Ing. Maroš Tunák, Ph.D.

Katedra hodnocení textilií

Datum zadání diplomové práce:

1. října 2013

Termín odevzdání diplomové práce:

19. května 2014

Ing. Jana Drašarová, Ph.D.

děkanka



doc. Ing. Vladimír Bajžík, Ph.D.

vedoucí katedry

V Liberci dne 3. února 2014

Prohlášení

Byla jsem seznámena s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména § 60 – školní dílo.

Beru na vědomí, že Technická univerzita v Liberci (TUL) nezasahuje do mých autorských práv užitím mé diplomové práce pro vnitřní potřebu TUL.

Užiji-li diplomovou práci nebo poskytnu-li licenci k jejímu využití, jsem si vědoma povinnosti informovat o této skutečnosti TUL; v tomto případě má TUL právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Diplomovou práci jsem vypracovala samostatně s použitím uvedené literatury a na základě konzultací s vedoucím mé diplomové práce a konzultantem.

Současně čestně prohlašuji, že tištěná verze práce se shoduje s elektronickou verzí, vloženou do IS STAG.

Datum:

Podpis:

PODĚKOVÁNÍ

V této části bych chtěla poděkovat svému vedoucímu práce doc. Ing. Marošovi Tunákovi, Ph.D. za věcné připomínky, rady a čas, který mi věnoval a Ing. Ivě Mertové za poskytnutí tkanin. Dále za podnětné rady a nápady bych chtěla poděkovat i mé rodině.

ANOTACE

Práce se zabývá rekonstrukcí vazby tkaniny pomocí obrazové analýzy. Navržený algoritmus se skládá ze tří základních kroků. V prvním kroku jsou pomocí průměrných profilů osnovy a útku nalezeny vazné body. Ve druhém kroku je prostřednictvím shlukovací metody K-průměrů nalezen počet barev. V posledním kroku byly určeny hrany mezi vaznými body pomocí Houghovy transformace. Výsledky ukázaly, že navržený algoritmus lze použít na vícebarevné tkaniny plátnové vazby a na dvoubarevné tkaniny keprové vazby.

Klíčová slova: obrazová analýza, průměrný profil osnovy a útku, vazný bod, shlukovací metoda K-průměrů, Houghova transformace.

ANNOTATION

Thesis deals with the reverse reconstruction of wave pattern using image analysis. The proposed algorithm consists of three main steps. Firstly, interlacing nodes are founded by gray line-profiles of the warp and weft. Secondly, the number of colors in the fabric is found through K-means clustering. In the last step, the edges between interlacing nodes were defined by Hough transformation. The results show that the created algorithm can be used for both multi-colored fabrics plain weave and two-tone twill fabric.

Keywords: image analysis, gray line-profiles of the warp and weft, interlacing node, K-means clustering, Hough transformation.

OBSAH

SEZNAM POUŽITÝCH ZKRATEK A SYMBOLŮ	9
ÚVOD.....	12
1. SOUČASNÝ STAV	13
2. TKANINY	20
2.1 Další parametry tkaniny	21
2.2 Základní pojmy.....	22
2.3 Základní vazby	23
2.3.1 Plátňová vazba	23
2.3.2 Keprová vazba	23
2.3.3 Atlasová vazba	24
2.4 Určení vazby tkaniny	25
3. ZPRACOVÁNÍ OBRAZU	26
3.1 Získání obrazu	26
3.1.1 Základní typy digitálního obrazu	27
3.1.2 Histogram	29
3.2 Předzpracování obrazu	31
3.2.1 Jasové transformace	31
3.2.2 Filtrace v prostorové oblasti	33
3.3 Segmentace obrazu	34
3.3.1 Prahování	34
3.3.2 Houghova transformace.....	36
3.4 Popis nalezených objektů.....	38
3.4.1 Sousednost	38
3.4.2 Vzdálenost mezi pixely	39
3.5 Porozumění obsahu obrazu	39
4. SADA VZORKŮ	40
4.1 Pořízení obrazu.....	41
5. POPIS EXPERIMENTU	43
5.1 Kroky algoritmu	43
5.1.1 Stanovení vazných bodů.....	44
5.1.2 Stanovení počtu barev	49
5.1.3 Stanovení hran mezi vaznými body	57

5.2	Aplikace algoritmu na vzorky tkanin	59
5.2.1	Vzorek P4	59
5.2.2	Vzorek P7	61
5.2.3	Vzorek P11	62
5.2.4	Vzorek P8	64
5.2.5	Vzorek P9	68
5.2.6	Vzorek K1	71
6.	VÝSLEDKY REKONSTRUKCE VAZBY TKANINY	75
	ZÁVĚR	78
	LITERATURA	80
	SEZNAM OBRÁZKŮ	83
	SEZNAM ROVNIC	85
	SEZNAM TABULEK	87
	SEZNAM PŘÍLOH	88

SEZNAM POUŽITÝCH ZKRATEK A SYMBOLŮ

2D	dvourozměrný
3D	trojrozměrný
HSV	barevný obraz (H barevný odstín, S sytost barvy, V jas)
FCM	shluková analýza (Fuzzy C-Means)
RGB	barevný obraz (R černá, G zelená, B modrá)
Lab	barevný obraz (L světlost, a složka barvy, b složka barvy)
P	plátňová vazba
K	keprová vazba
A	atlasová vazba
Z	směr řádkování doprava
S	směr řádkování doleva
tzn.	to znamená
např.	na příklad
apod.	a podobně
px	pixel
LUT	vyhledávací tabulka (look up table)
DFT	Fourierova transformace (discrete Fourier transform)
IPT	zpracování obrazu (image processing toolbox)
V	oblast vazného bodu
P_s	plošná měrná hmotnost [kg/m^2]
m_t	hmotnost textilie [kg]
S_t	obsah (plocha) textilie [m^2]
PZ	plošné zakrytí tkaniny [-]
S_n	plocha nití ve tkanině [m^2]
S_o	setkání osnovy [%]
S_u	setkání útku [%]
l_o	délka osnovní nitě [m]
l_u	délka útkové nitě [m]
l_t	délka tkaniny [m]
N_o	počet osnovních vazných bodů ve střídě [-]
N_u	počet útkových vazných bodů ve střídě [-]

PC	postupové číslo [-]
$f(x,y)$	obrazová funkce vstupního obrazu [-]
x	index řádku [-]
y	index sloupku [-]
N	počet sloupků [-]
M	počet řádků [-]
L	počet úrovní jasu v obraze [-]
b	počet bitů na jeden obrazový element [-]
$P(r_k)$	odhad pravděpodobnosti [-]
r_k	k-tá úroveň v obraze [-]
n_k	počet pixelů s úrovní r_k [-]
MN	celkový počet pixelů v obraze [-]
$g(x,y)$	výstupní obraz [-]
T	operátor (prostorová filtrace) [-]
X, Y	body [-]
x_i, y_i	souřadnice bodu [-]
D_e	Euklidovská vzdálenost [px]
K	počet shluků [-]
μ_i	těžiště shluku [px]
X_j	data pozorování [-]
$filtr$	velikost okolí pro metodu klouzavých průměrů [-]
$f(x_i)$	hodnota pixelu v řádcích [px]
$f(x_j)$	hodnota pixelu ve sloupcích [px]
i	řádek [-]
j	sloupek [-]
G_O	průměrná hodnota šedi ve směru osnovy [px]
G_U	průměrná hodnota šedi ve směru útku [px]
PK_O	klouzavý průměr pro průměrný profil osnovy [px]
PK_U	klouzavý průměr pro průměrný profil útku [px]
U	lokální minimum [px]
$okoli$	velikost okolí pro výpočet globálního maxima/minima [-]
$vzdalenost$	zmenšení vazného bodu pro výpočet průměrné barvy [px]
$f(\bar{R}, \bar{G}, \bar{B})$	průměrná hodnota pixelů [px]

R_I	intenzita červeného kanálu [px]
G_I	intenzita zeleného kanálu [px]
B_I	intenzita modrého kanálu [px]
n	počet pixelů [-]
M	mezishluková suma čtverců [px ²]
S	směrodatná odchylka [px]
$prechod$	velikost okolí pro výpočet směrodatné odchylky [px]
$prah$	práh pro výpočet hran v obraze [-]
n_p	počet pixelů v určité oblasti [-]
max	maximální hodnota [-]
min	minimální hodnota [-]
k	směrnice přímky [-]
q	posun přímky [-]
R	práh pro prahování [-]
R_1	první práh u víceúrovňového prahování [-]
R_2	druhý práh u víceúrovňového prahování [-]
G_1	první skupina pixelů při aplikaci globálního prahování [-]
G_2	druhá skupina pixelů při aplikaci globálního prahování [-]
m_1	průměrná úroveň šedi pro G_1 [px]
m_2	průměrná úroveň šedi pro G_2 [px]
ΔR	rozdíl prahových hodnot [-]
s	hodnota pixelu po zpracování (lineární transformační funkce) [px]
r	hodnota pixelu před zpracováním (lineární transformační funkce) [px]
v	počet vazných bodů v obraze [-]

ÚVOD

Tkanina, plošná textilie, je tvořena nejčastěji dvěma navzájem na sebe kolmými soustavami nití, osnovou a útkem. Důležitými parametry tkanin jsou plošná hmotnost, tloušťka, dostava nití, vazba a barevné provedení nití. Zjišťování těchto parametrů je velmi obtížné a časově náročné, někdy i nepřesné. Díky technickým pokrokům v oblasti počítačů a obrazové analýzy je nyní zkoumání parametrů jednodušší, rychlejší a přesnější.

Cílem práce je navrhnout algoritmus v programu MATLAB, pomocí kterého bude automaticky provedena rekonstrukce vazby tkaniny.


Navržený algoritmus se skládá ze tří základních kroků. V prvním kroku jsou pomocí průměrných profilů osnovy a útku nalezeny jednotlivé vazné body. Ve druhém kroku je prostřednictvím shlukovací metody K-průměrů stanoven počet barev ve tkanině. A ve třetím kroku jsou hranou odděleny rozdílné vazné body. Nejprve jsou hranou odděleny odlišné barvy v obraze a poté pomocí Houghovy transformace, která určuje převažující směr vláken ve vazném bodě, jsou odděleny osnovní vazné body od útkových.

V první kapitole jsou popsány vybrané studie, které se zabývají rekonstrukcí vazby tkaniny pomocí nástrojů obrazové analýzy. Ve druhé a třetí kapitole je definována tkanina se základními parametry a popsány metody obrazové analýzy, které byly použity v navrženém algoritmu. Ve čtvrté kapitole je uveden přehled vzorků tkanin a v následujících kapitolách jsou popsány jednotlivé kroky navrženého algoritmu, aplikace algoritmu na sadu vzorků a souhrnný přehled zrekonstruovaných obrazů tkaniny.


1. SOUČASNÝ STAV

Práce se zabývá rekonstrukcí vazby tkaniny pomocí nástrojů obrazové analýzy. V současné době se tímto tématem zabývá několik studií, některé z nich jsou uvedeny v následujícím textu.


Článek [1] popisuje rekonstrukci vazby prostřednictvím počítačové analýzy. Obraz nejprve prošel základními procesy předzpracování, to znamená, že byla vybrána vhodná část obrazu, která reprezentuje celý snímek. Poté byla provedena šedotónová transformace (viz obr. 1 a 2), byl potlačen šum a byly zvýrazněny kontrasty mezi odstíny v obraze. V každém obraze se objevuje šum, který je způsoben např. nerovnoměrným nasvícením. K odstranění šumu byla v práci použita kombinace průměrové a mediánové filtrace. Dále byly vykresleny profily sloupků a řádků obrazové matice v šedotónových odstínech. Profil osnovy znázorňuje průměrné odstíny šedi zjištěné po řádcích a profil útku znázorňuje průměrné odstíny šedi ve sloupcích. Vrcholy křivky představují osnovu či útek a údolí představují mezery mezi nitěmi (viz obr. 3). Jejich lokální maxima znázorňující vzdálenost mezi nitěmi (rozteče) byla proložena mříží, tím vznikla souřadnicová síť tkaniny. Získaná síť byla zakódovaná pomocí 0 a 1 (0 znázorňuje osnovní nit a 1 útkovou nit). Řádky matice zobrazují útek a sloupky osnovu. Po těchto operacích pomocí navrženého algoritmu je možné automaticky rozpoznat vzor tkaniny. Metoda je vhodná pro plátňové, keprové a atlasové vazby, které mají jinou barevnou nit v osnově i v útku. Pro tyto tkaniny lze metodu považovat za efektivní.



Obr. 1 Vstupní obraz (RGB).



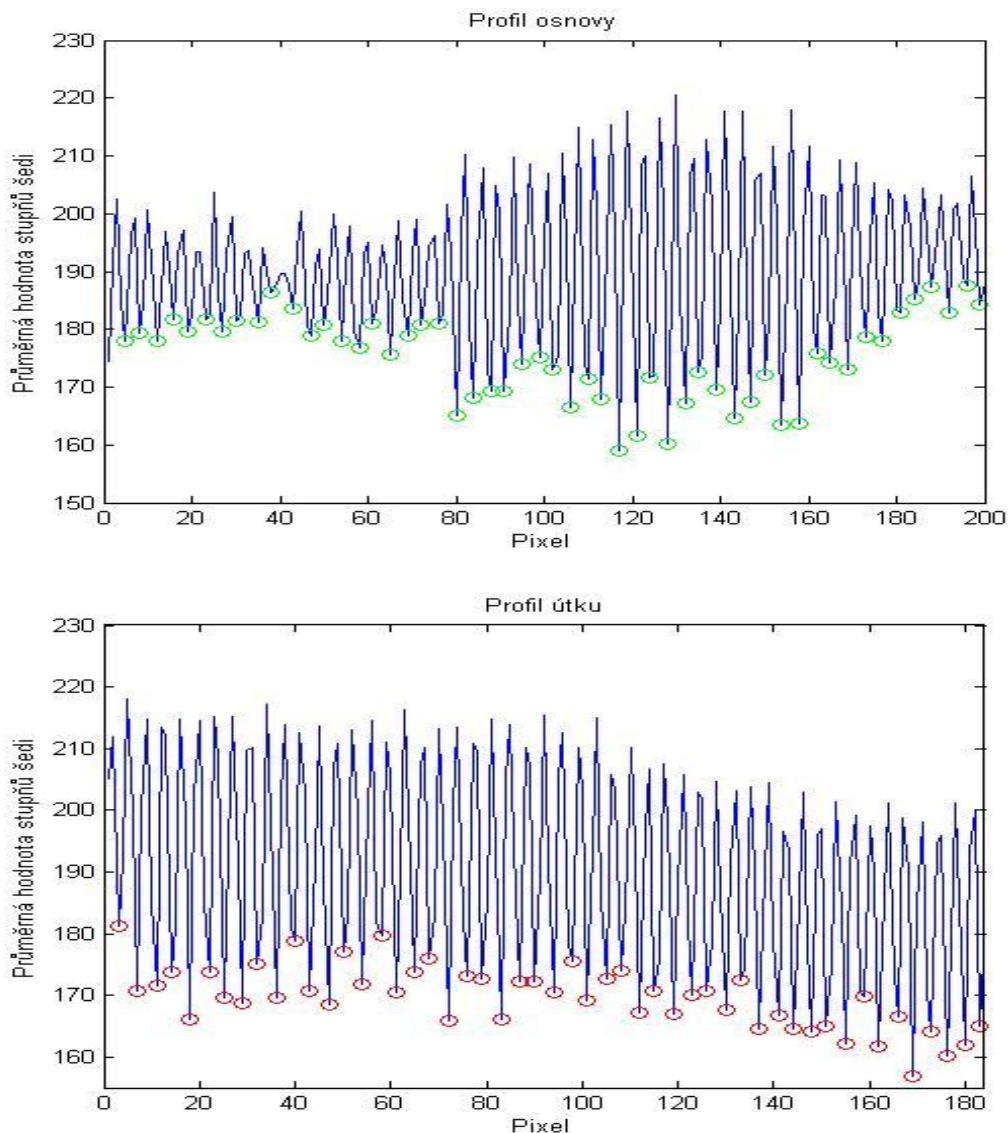
Obr. 2 Šedotónový obraz.



Obr. 3 Průměrný profil osnovy a útku.

Článek [2] popisuje, jak ve tkanině nalézt dostavu osnovy a útku. Metodu autoři aplikovali na tři tkaniny v plátnové vazbě, na dvě v keprové a na jednu tkaninu v atlasové vazbě. Tato metoda je závislá na kvalitě pořízení obrazu, který je v odstínech šedi. Šedotónový obraz byl převeden do binárního tvaru s prahovou hodnotou 70, černá barva v obraze značí mezery mezi nitěmi a bílá barva znázorňuje nitě. Dále byl vytvořen profil osnovy a útku, jejichž grafy obsahují lokální minima a maxima. Průběh grafů nebyl hladký, proto v něm bylo nalezeno velké množství minim. Z tohoto důvodu autoři vytvořili algoritmus, který dovede z jeho okolí rozeznat, zda se jedná o lokální či globální minimum. Pokud byl aktivní bod nižší než stanové okolí, potom se jednalo

o lokální minimum. Tato lokální minima znázorňují ve tkanině mezery mezi nitěmi. Metodu lze aplikovat na plátňové a keprové tkaniny, naopak na atlasovou vazbu metoda vhodná není. Kvůli husté dostavě osnovních nití je velmi obtížné nitě od sebe identifikovat. Těžké je rozeznat i útkové nitě, protože jsou zakryty osnovními.



Obr. 4 Vykreslená lokální minima.

Autoři článku [3] porovnávají navržený algoritmus hledající průměrné profily soustav metodou založenou na 2D DFT. Obrazy tkaniny byly pořízeny v odstínech šedi, následně byly převedeny do binárních obrazů, na kterých jsou mezery mezi nitěmi zobrazeny černou barvou. Z šedotónových obrazů byly vykresleny průměrné profily osnovy a útku, z kterých byla dále nalezena lokální minima znázorňující mezery mezi nitěmi (viz obr. 4). Zeleně zakroužkovaná minima znázorňují mezery

mezi útkovými nitěmi a červeně zakroužkovaná minima značí mezery mezi osnovními nitěmi. Důležitým parametrem pro vyhledání lokálních minim je vhodně zvolená velikost filtru, která nesmí být větší než je hodnota pixelu odpovídající průměru příze. Metoda byla aplikována na tři plátňové, dvě keprové a jednu atlasovou tkaninu. Výsledky prokázaly, že pro vyhledávání průměrných profilů soustav je vhodnější použít navrženou metodu založenou na 2D DFT, protože ji lze aplikovat na širší okruh tkanin.

Automatickým rozpoznáním tkaninového vzoru s využitím digitální obrazové analýzy se zabývá článek [4]. Vzorek byl z vrchu osvětlen halogenovými žárovkami. Tmavá místa na snímku znázorňují osnovní a útkové nitě, naopak světlá místa, kde prochází světlo, zobrazují mezery mezi nitěmi. Algoritmus rekonstrukce se skládá ze tří kroků. V prvním kroku byla provedena Gaussova filtrace z důvodu redukce šumu a prahování obrazu. Dále byly rozpoznány bílé objekty, které se propojily mříží. Poté byly odstraněny chybové linie a vložily se linie chybějící. Na závěr vznikla data osnovních a útkových vazných bodů. Ve druhém kroku byl původní binární obraz převeden do šedotónového. Z osnovních a útkových bodů byly vytvořeny profily, ve kterých byla nalezena lokální minima a jejich vzájemné vzdálenosti. Dále byl vypočítán poměr stran a byly určeny vazné body. Ve třetím kroku se obraz konvertoval do HSV barevného modelu, který obsahuje pouze 256 barev, barevný model RGB obsahoval okolo 17 mil. barev. Dále byly určeny indexy barev a konečný počet barev. Na závěr byla zkompletována data barevných nití. Metodu lze použít pro dvoubarevné plátňové a jednobarevné keprové vazby, je určena pouze pro jednovrstvé tkaniny.

Článek [5] se zabývá analýzou tkaniny pomocí zpracováním obrazu. Analýzou lze identifikovat strukturní (vazba, počet nití) a zákrutové charakteristiky (směr zákrutu a úhel). Velikost reálného vzorku byl $1,83 \times 1,83$ mm a jeho digitální obraz byl 512×512 pixelů (0-255). Šum v obraze byl částečně odstraněn mediánovou filtrací s maskou 3×3 , k rozmazání chlupatosti a odstávajících vláken byl použit filtr dolní propust. K vytvoření grafu je důležité nejprve najít nitě a jednotlivé vazné body, graf poté slouží k určení vazby tkaniny. Dále byly porovnány řádky a sloupky, dokud nebyly objeveny dva stejné. Aby byl obraz rovnoměrně nasvícen, byly použity dvě lampy. Diagram se čtvercovými políčky znázorňuje osnovní a útkové body, kde osnovní body jsou zakresleny černě. Pomocí analýzy lze rozpoznat s velkou přesností plátňovou,

keprovou a atlasovou vazbu. Výsledky práce ukázaly, že metoda není vhodná pro vazby, které mají vysokou dostavu nití nebo pro tkaniny, jejichž nitě nejsou na sebe vzájemně kolmé. Účinnost algoritmu klesá s rostoucím rozdílem barev mezi nitěmi.

Práce [6] popisuje aplikaci počítačového vidění a klasifikaci tkanin. Pro předzpracování obrazu byl použit mediánový filtr o velikosti 3×3 . Dále byl použit FCM (Fuzzy C-Means) shlukovací algoritmus k identifikaci osnovních a útkových vazných bodů. FCM shlukovací algoritmus rozděluje všechny osnovní a útkové vazné body do skupin. Tím vznikne matice nul (skupiny osnovních vazných bodů) a jedniček (skupiny útkových vazných bodů), neboli černobílá matice. Klasifikace byla provedena ve dvou krocích. V prvním kroku byly tkaniny rozděleny podle typu vazby a ve druhém kroku byly vytvořeny jejich podkategorie. Metoda se používá pro plátňové, keprové a atlasové vazby.

Další skupina autorů se zabývá automatickou detekcí rozvržení barevných nití ve tkanině pomocí FCM algoritmu [7]. Nejprve byl obraz převeden z RGB barevného modelu do modelu Lab. Klasifikace pixelů byla provedena pomocí FCM shlukovacího algoritmu, pomocí které byl nalezen počet nití. Dále pomocí Laplacianovy masky byla ve skupině s minimálním počtem pixelů provedena detekce hran nití. Houghova transformace byla aplikována na hranách bílých pixelů, pomocí které byl zjištěn úhel natočení osnovních a útkových nití. Experiment byl proveden na dvou vzorcích, první byl ze tří světlejších odstínů a druhý ze tří tmavších. Metodu lze použít pouze pro plátňové vazby. U atlasu, kde je vyšší dostava nití, účinnost algoritmu klesá.

Autoři v práci [8] navrhuji novou konstrukční metodu grafického znázornění vazby tkaniny. Data korespondující s řadou centrálních bodů byla získána obkreslením každé nitě. Jediný požadavek pro konstrukci schématu je identifikace protínajících se míst osnovy a útku. Metoda se skládá ze dvou kroků, v prvním kroku byla nalezena všechna protnutí a ve druhém kroku byla identifikována protínající se místa a bylo vytvořeno schéma tkaniny. Poté byla data rozdělena do dvou skupin dle vypočítaného gradientu linie nitě. Příze v delší gradientové skupině jsou osnovní. Byly testovány dva textilní vzorky, keprová tkanina s vlákny o průměru okolo 0,1 mm a dvouvrstvá tkanina

s průměrem vláken přibližně 0,1 mm. Účinnost navrhované metody byla experimentálně potvrzena.

Článek [9] se zabývá integrovaným hardwarem a softwarem, který automatizuje proces analýzy tkané struktury. Přestože analýza je jedním z nejvýznamnějších kroků textilního návrhářství a kontroly kvality, je závislá na lidských dovednostech s primitivním zařízením. V této studii byl vytvořen specializovaný hardwarový systém, jehož cílem bylo získat obrazy s vysokým rozlišením. Poté byla technika v obraze aplikována pro hledání protínajících se nití osnovy a útku. Na závěr pomocí sítě byla stanovena struktura tkaniny.

V článku [10] autoři popisují rozpoznávací systém založen na obrazové analýze, který dokáže určit strukturní parametry barevné příze tkaniny (dostava, vzor, rozvržení nití a vazba). Pomocí Houghovy transformace byl zjištěn úhel zešikmení osnovy a útku, poté následovala metoda „steering“ filtr, která se používá ke zlepšení obrazu podél určitého směru. Filtr byl použit k analýze struktury a k detekci hran. Metodu šedé projekce („gray-projection“) lze aplikovat pouze na bílé nebo světlé barvy. Nelze ji použít u tmavých barev, protože vyhledává příze v obraze tkaniny, z tohoto důvodu byla navržena metoda „gray-grads“. Před aplikací metody musí být obraz převeden z barev RGB do šedotónových. Dostava nití se počítá souběžně s detekcí vazných bodů. Počet nití byl získán ze shlukovací analýzy, dále pomocí FCM algoritmu byly určeny vazné body. Periodická extrakční metoda byla použita ke zjištění barevného efektu. Vzor tkaniny byl určen z databáze tkanin. V databázi byl barevný efekt porovnáván se základními vzory jeden po druhém, dokud nebyl určen výsledek. V popsáném experimentu bylo testováno dvacet tkanin, dvě z nich byly špatně rozpoznány kvůli povrchové vadě. Tyto dvě tkaniny byly použity k ověření algoritmu. Popsaný systém nelze aplikovat na žakárový vzor ani na vícevrstvou tkaninu.

V práci [11] se popisuje, jak lze zjistit pomocí FCM vazbu. Aby byly dobře nalezeny osnovní a útkové vazné body, musel obraz obsahovat barvy odstínů šedi. Zlepšení obrazu bylo dosaženo přičtením top-hat transformace a následným odečtením bottom-hat transformace od originálního obrazu. Dále byla pro každý vazný bod vypočítána statistika prvního (průměr a směrodatná odchylka) a druhého řádu (kontrast a

homogenita). Na závěr byl automaticky rozpoznán vzor tkaniny použitím FCM algoritmu. V prvním kroku FCM se provádí odhad počáteční centrální hodnoty, avšak tento odhad je často nesprávný. FCM přiřazuje každému datovému bodu stupeň, po několika opakováních se najde správný centrální bod. Metodu lze aplikovat na obrazy plátňové, keprové a atlasové vazby, které se skládají z 256 odstínů jedné barvy. V experimentu byl použit strukturní prvek o velikosti 4×4 , který obsahoval samé jedničky. Bylo zjištěno, že metodu lze aplikovat pouze na jednobarevné jednovrstvé tkaniny. Pokud tkanina má chlupatější povrch, je zjištěno méně charakteristik.

Článek [12] se zabývá analýzou barev a vzoru potištěné tkaniny pomocí shlukovací metody. Nejprve byla tkanina nasnímána a převedena do digitálního tvaru. Na vyhlazení barev byl použit průměrovací filtr, dále byla data rozdělena do skupin. U vzorů tvořenými rozlišnými barvami lze vypočítat statistické hodnoty, jako je např. plocha, rozsah, orientace a střed shluku. Pomocí FCM algoritmu byl vyhodnocen vztah mezi skupinami dat. Poté bylo vytvořeno C-rozdělení, které je velmi podobné původní struktuře. Použitím specifického kritéria pro shluky byl nalezen konečný počet shluků. Přepsáním hodnot pixelů ze všech skupin byl vytvořen shlukový distribuční diagram. Na závěr byly vypočteny barevné a vzorové rysy potištěné tkaniny. Výsledky prokázaly, že metodu lze považovat za efektivní.

Metoda popsaná v práci [13] se zaměřuje na tkaniny obsahující chlupaté příze. Proces se skládal ze dvou základních kroků, nejprve bylo zjištěno rozložení nití pomocí sérií technik zlepšující obraz a metodou vycházející z detekce hran. Ve druhém kroku použitím radonové transformace byly rozpoznány vazné body. Radonová transformace detekuje orientaci vláken ve vazných bodech a určuje strukturu tkaniny a vzor. Vlnková transformace, založena na hranové detekci, snižuje vliv chlupatosti. V práci byly zkoumány tři typy tkanin, tkaniny z jednoduchých přízí, z dvojitých přízí a ze zakroucených přízí. Celkem bylo testováno čtyřicet vzorků, devatenáct z nich bylo správně identifikováno. Metodu lze použít pouze na jednovrstvé tkaniny.

2. TKANINY

Tkanina je plošná textilie vyrobena alespoň ze dvou soustav nití, osnovy a útku, které jsou vzájemně na sebe kolmé. Důležité parametry definující tkaninu jsou materiálové složení použitých přízí, plošná měrná hmotnost, tloušťka, dostava osnovy a dostava útku, setkání, vazba a lineární či plošné zakrytí.

Materiálové složení

Pro tkaní plošných textilií se používají přírodní nebo syntetické materiály. Použité příze mohou být jednokomponentní nebo směšové, které se skládají ze dvou či více komponent v určitém procentním poměru. Příze mohou být hladké, skané nebo efektní [14].

Plošná měrná hmotnost P_s [kg/m²]

Plošná hmotnost představuje podíl hmotnosti textilie a jejího obsahu. Plošná měrná hmotnost P_s je hmotnost tkaniny o ploše 1 m² v klimatizovaném prostředí (teplota vzduchu 20°C, vlhkost vzduchu 65%) [13]. Plošná hmotnost je vyjádřena následující rovnicí

$$P_s = \frac{m_t}{S_t}, \quad (1)$$

kde m_t je hmotnost textilie a S_t je plocha textilie.

Tloušťka

Tloušťka materiálu je vzdálenost mezi přitlačnou deskou a podložkou při stanoveném přitlaku a ploše přitlačné čelisti. Přitlak zajišťuje rovnoměrné podmínky pro určitý typ materiálu [14].

Dostava osnovy a dostava útku

Dostava je vyjádřena počtem nití jedné soustavy na jednotku délky (zpravidla na 100 mm) druhé soustavy [14].

Vazba

Podle způsobu provázání se rozlišují základní, odvozené, složené vazby a složené vazební techniky. Vazba tkaniny ovlivňuje pružnost, tuhost, pevnost, splývavost, vzhled, tepelnou odolnost a omak tkaniny [14].

Plošné zakrytí $PZ [-]$

Plošné zakrytí tkaniny vyjadřuje podíl plochy nití ve tkanině a celkové plochy tkaniny, vypočítá se dle následujícího vztahu

$$PZ = \frac{S_n}{S_t}, \quad (2)$$

kde S_n je plocha nití ve tkanině a S_t je celková plocha tkaniny.

Setkání osnovy a útku $S_o, S_u [\%]$

Setkání vyjadřuje zkrácení nitě, které bylo způsobeno tkaním. Udává se v procentech z rozměru tkaniny s přesností 0,1 % [21], [22]. Setkání osnovy je vyjádřeno vztahem

$$S_o = \frac{l_o - l_t}{l_t} \times 100, \quad (3)$$

kde l_o je původní délka osnovní nitě a l_t je délka tkaniny.

Setkání útku je vyjádřeno podobně jako setkání osnovy

$$S_u = \frac{l_u - l_t}{l_t} \times 100, \quad (4)$$

kde l_u je původní délka útkové nitě a l_t je délka tkaniny.

2.1 Další parametry tkaniny


Dalšími důležitými parametry jak pro výrobu, tak pro spotřebitele jsou délka tkaniny udávaná v metrech, šířka tkaniny v centimetrech, kraje tkaniny (většinou jsou odlišeny vazbou, barvou nebo jakostí osnovních nití), líc a rub tkaniny, směr osnovy a útku, vzor snovaný (střída barevných nití v osnovní soustavě), pořad házený (barevné vzorování

ve směru útku), podélný či příčný řez tkaninou, hmotnost tkaniny v gramech a zastoupení osnovy a útku ve tkanině v procentech [15], [19].

2.2 Základní pojmy

Mezi základní pojmy v oblasti textilií patří osnova, útek, vazba, dostava, osnovní a útkový vazný bod, střída vazby, vzornice vazby, technická vzornice, příčný a podélný řez a číslování nití. Některé z pojmů jsou vysvětleny níže [16], [17]:

- osnova – soustava nití ve směru délky tkaniny,
- útek – nit kolmá k osnově,
- vazba tkaniny – způsob provázání osnovní a útkových nití,
- dostava tkaniny – parametr udávající počet nití na 100 mm,
- vazný bod – překřížení osnovní nitě s útkem (viz obr. 5),
 - osnovní vazný bod – pokud osnovní nit leží nad útkovou nití,
 - útkový vazný bod – pokud útková nit leží nad osnovní nití,



Obr. 5 Vazný bod: a) osnovní, b) útkový.

- střída vazby – část vazby, která se v celé ploše, s výjimkou krajů tkaniny, pravidelně opakuje (osnovní body se ve střídě značí černě, opakování střídý vazby červeně),
- vzornice vazby – zakreslení osnovních vazných bodů na vzornicový papír,
- osnovní/útková vazba – na lící straně tkaniny je převaha osnovních vazných bodů nad útkovými/převaha útkových vazných bodů nad osnovními,
- oboustranná vazba – stejný počet osnovních a útkových vazných bodů,

- technická vzornice – zahrnuje vzornici vazby, rozkreslení po střídě, návod do paprsku, návod do listů, závěs listů a vzornici pro karty listového stroje.

2.3 Základní vazby

Vazba dodává tkanině určité vlastnosti jako je např. pevnost, splývavost, tuhost, drsnost, vzhled a omak. Mezi základní vazby tkanin patří plátnová, keprová a atlasová vazba [18].

2.3.1 Plátnová vazba

Jedná se o nejjednodušší vazbu, je nejpevnější a má nejdelší životnost. Střída vazby je tvořena ze dvou osnovních nití a dvou útkových nití. Hlavní charakteristický rys je pravidelné střídání osnovních a útkových vazných bodů a stejný vzhled lící i rubní strany. Mezi odvozené plátnové vazby patří ryps a panama [18].

Zápis vazby:

$$P \frac{N_o}{N_u}, \quad (5)$$

kde P značí plátno, N_o je počet osnovních vazných bodů ve střídě a N_u je počet útkových vazných bodů. Na obr. 6a) je znázorněna vazba $P \frac{1}{1}$.


2.3.2 Keprová vazba

Hlavní charakteristika keprové vazby je šikmé řádkování, pravým či levým směrem. Nejmenší možná střída jsou tři nitě útkové a tři osnovní. Rozlišujeme osnovní a útkové keprové vazby. Odvozené keprové vazby jsou zesílený kepr, víceřádkový kepr, hrotový kepr, křížový kepr, lomený kepr a mnoho dalších [18].

Zápis vazby:

$$K \frac{N_o}{N_u} Z (S), \quad (6)$$

kde K znamená keprová vazba, N_o je počet osnovních vazných bodů ve střídě a N_u je počet útkových vazných bodů, Z je směr řádkování doprava a S je směr řádkování doleva. Na obr. 6b) je znázorněna vazba $K \frac{2}{1} Z$.



Obr. 6 Vazba tkaniny: a) plátnová vazba, střída 2×2, b) pětivazný útkový atlas s postupovým číslem 2, c) třívazný osnovní kepr pravého směru.

2.3.3 Atlasová vazba

Základní rys atlasové vazby je lesk. Nejmenší střída vazby atlasu je pět nití osnovních a pět nití útkových. Atlas může být buď osnovní, nebo útkový, podle převažujících vazných bodů ve střídě. Vazné body se vzájemně nedotýkají. Při konstrukci atlasové

vazby se stanovuje postupové číslo, které určuje, na kolikáté osnovní niti je v následujícím řádku další vazný bod. K odvozeným atlasovým vazbám patří nepravidelné, smíšené, zesílené, stínované a přísazované atlasy [18].

Zápis vazby:

$$A \frac{N_o}{N_u} (P\check{C}), \quad (7)$$

kde A značí atlasovou vazbu, N_o je počet osnovních vazných bodů ve střídě a N_u je počet útkových vazných bodů a $P\check{C}$ je stanové postupové číslo. Na obr. 6c) je znázorněna vazba $A \frac{1}{4} 2$.

2.4 Určení vazby tkaniny

Pro zjištění vazby u jednoduchých tkanin se používá mikroskop. U hustších vazeb nebo tkanin obsahující efektní nitě je potřeba tkaninu postupně párat a zakreslovat do vzornice. Nejefektivnějším postupem je u zkoumané textilie odstranit osnovní a útkové nitě v délce 1 cm. Na vzniklé třísní jsou dobře znatelné osnovní a útkové vazné body. Po zakreslení jedné nitě následuje další, dokud se vazba nezačne opakovat. Poté lze vazbu identifikovat [18].

Práce je zaměřena na testování tkanin plátňové a keprové vazby. Metodika je založena na zpracování obrazové informace, v další kapitole bude uveden stručný úvod do analýzy obrazu.

3. ZPRACOVÁNÍ OBRAZU

Cílem práce je provést rekonstrukci vazby tkaniny s využitím nástrojů obrazové analýzy, všechny algoritmy budou provedeny v programu MATLAB. Obecně proces zpracování obrazu prochází těmito kroky, které budou jednotlivě popsány v podkapitolách:

1. získání obrazu,
2. předzpracování obrazu,
3. segmentace obrazu,
4. popis nalezených objektů,
5. porozumění obsahu obrazu.

3.1 Získání obrazu

Cílem snímání obrazu je vytvořit digitální obraz procesem digitalizace. Jedná se o převedení vstupního spojitého signálu určitého obrazu do diskrétního tvaru. Vstupní signál je vzorkován a kvantován, jejichž výsledkem je matice čísel [23].

Obraz je vícerozměrný signál, se kterým se lidé neustále střetávají. Z obrazu lze zjistit např. velikost, polohu nebo charakteristiky jasu vybraného objektu. Obraz může být modelován pomocí obrazové funkce, tzn. pomocí spojitě skalární funkce f dvou nebo tří proměnných [20].

Digitalizovaný obraz v počítači je vyjádřen obrazovou funkcí $f(x,y)$, která je interpretována maticí

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0,N-1) \\ f(1,0) & f(1,1) & \cdots & f(1,N-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) & \cdots & f(M-1,N-1) \end{bmatrix}, \quad (8)$$

kde N je počet sloupků, M je počet řádků v matici, x je index sloupku a y je index řádku.

Jednotlivé prvky matice se nazývají obrazové elementy, pixely nebo body. Pixel je nejmenší nedělitelná jednotka v obraze. Aby obraz mohl být zpracován v počítači, musí být obrazová funkce digitalizována. Digitalizace je převod spojitého analogového signálu na signál digitální [20], [21].

Digitální obraz je množina pixelů vyjádřena maticí o velikosti $M \times N$, kde M značí počet řádků a N počet sloupců. Hodnota každého elementu je rovna jasu obrazu v daném místě. Výsledkem vzorkování obrazu (digitalizace hodnot souřadnic) je matice o velikosti $M \times N$, kdy je zároveň určena i vzdálenost mezi pixely a výsledkem kvantování (digitalizace hodnot amplitudy) je zjištěn počet L úrovní. Počet úrovní jasu je vyjádřen vztahem

$$L = 2^b, \quad (9)$$

kde L je počet úrovní jasu a b je počet bitů na jeden obrazový element, který je z intervalu $[0, L-1]$. Obvykle se používá 8 bitů na obrazový element [21] - [24].

3.1.1 Základní typy digitálního obrazu

Digitální obraz se vyskytuje nejčastěji ve třech typech (binární obraz, šedotónový obraz a barevný obraz - model RGB), (viz obr. 7), které se liší množstvím zachycených informací a způsobem jejich ukládání.

Binární obraz

Jedná se o matici o velikosti $M \times N$, jejíž prvky nabývají pouze dvou hodnot $L = 2$ ($b = 1$ bit). Nula značí černou barvu (pozadí) a jednička bílou (objekt) [22]. Obrazová funkce pro binární obraz je dle [23]

$$f(x, y) = \begin{cases} 0 & \text{černá (pozadí)} \\ 1 & \text{bílá (popředí, objekt)}. \end{cases} \quad (10)$$

Příklad binárního obrazu tkaniny plátňové vazby skládající se ze dvou rozdílných barev v osnově a v útku je uveden na obr. 7a).

Šedotónový (monochromatický) obraz

Šedotónový obraz reprezentuje matici o velikosti $M \times N$. Každý pixel má nejčastěji 256 úrovní šedi (0-255), tedy $L = 2^8 = 256$ ($b = 8$ bit). Nula značí nejtmaší odstín a 255 naopak nejsvětější odstín v obraze [22]. Obrazová funkce pro šedotónový obraz je dle [23]

$$f(x, y) = 0, 1, 2, \dots, 255. \quad (11)$$


Příklad šedotónového obrazu tkaniny je zobrazen na obrázku 7b).

Barevný obraz model RGB

Barevný obraz se skládá ze tří kompozitních barev RGB, R značí červenou barvu (Red), G představuje zelenou barvu (Green) a B je modrá barva (Blue). Proto je matice trojrozměrná $M \times N \times 3$. Výsledná barva každého bodu se skládá ze tří bytů, jejichž smícháním vznikne opticky jiná barva. Každý byt odpovídá jedné z kompozitních barev a vyjadřuje intenzitu odstínu barvy od nejslabší po nejsytější odstín (256 odstínů). Každý pixel může obsahovat až 17 miliónů barev (2563). Přibližná hodnota 17 miliónů barev vychází ze vztahu (9) po dosazení $L = 23 \times 8$ [21] - [23]. Obrazová funkce je dle [23]

$$f(x, y) = [R \ G \ B]. \quad (12)$$

Příklad barevného obrazu tkaniny je zobrazen na obrázku 7c).



Obr. 7 Typy digitálních obrazů: a) binární obraz, b) šedotónový obraz, c) barevný obraz RGB.

Černá barva obsahuje hodnoty $[0 \ 0 \ 0]$, naopak bílá barva se skládá z hodnot $[255 \ 255 \ 255]$ a červená barva obsahuje hodnoty $[255 \ 0 \ 0]$. Pokud jednotlivé složky obsahují stejné hodnoty, jedná se o odstín šedi [21].

3.1.2 Histogram

Histogram je sloupcový diagram, na jehož vodorovné ose je vyneseno 256 bodů odpovídajících 256 odstínům v obraze (pro $L = 2^8$) rozděleny do tříd a na svislé ose je znázorněn počet pixelů v dané úrovni jasu r_k pro $k = 0, 1, 2, \dots, L-1$.


Histogram binárního obrazu (viz obr. 8b) obsahuje pouze dvě třídy, které obsahují jedničky (bílá barva) a nuly (černá barva). Histogram šedotónového obrazu (viz obr. 8d) se skládá z 256 odstínů šedi (pro $L = 2^8$) a histogram barevného obrazu RGB (viz obr. 8f) je tvořen třemi barevnými kanály (červený, zelený a modrý), každý z nich se skládá z 256 odstínů, tj. 17 mil. barev.

Normalizovaný histogram


Každý pixel v histogramu je vydělen celkovým počtem pixelů v obraze. Normalizovaný histogram je dán vztahem

$$P(r_k) = \frac{n_k}{MN}, \quad k = 0, 1, 2, \dots, L - 1, \quad (13)$$


kde $P(r_k)$ je odhad pravděpodobnosti výskytu úrovně r_k v obraze, n_k je počet pixelů s úrovní r_k , MN je celkový počet pixelů v obraze a L je celkový možný počet úrovní šedi. Součet všech prvků normalizovaného histogramu je roven 1 [23].




a)




b)




c)



d)



e)



f)

Obr. 8 Typy obrazů a jejich histogramy: a) binární obraz, b) histogram binárního obrazu, c) šedotónový obraz, d) histogram šedotónového obrazu, e) barevný obraz RGB, f) histogram barevného obrazu.

3.2 Předzpracování obrazu

Cílem procesu předzpracování je zlepšení nasnímaného obrazu, potlačení šumu, úpravy jasu a kontrastu, úpravy histogramu, zostření obrazu a zmenšení či zvětšení obrazu. Zpracování v prostorové oblasti je vyjádřeno vztahem

$$g(x, y) = T[f(x, y)], \quad (14)$$

kde $f(x, y)$ je vstupní obraz, $g(x, y)$ je výstupní obraz a T je operátor definovaný na okolí bodu (x, y) [23].

3.2.1 Jasové transformace


Jasové transformace jsou bodové operace prováděné na jednotlivých pixelech obrazu. Používají se pro zlepšení obrazu, kterého lze dosáhnout změnou jasu nebo kontrastu. Aplikátor může být použit na jeden obraz, nebo na sadu obrazů. Proces zahrnuje posun počátku okolí z pixelu na pixel, kde je aplikován operátor T podle vztahu (14). Nejmenší možné okolí bodu je 1×1 , potom g závisí pouze na hodnotě f v jednom bodě (x, y) .

Jednou z možností pro změnu jasu je použití vyhledávací tabulky (LUT), která pracuje na principu klíče a hodnoty. Pro zvýšení kontrastu se nejčastěji používá ekvalizace histogramu, kterou je histogram roztažen. Protože po ekvalizaci histogramu má obraz pokryt celý rozsah úrovní šedi, má výsledný obraz vysoký kontrast. Na následujícím obrázku (obr. 9) je znázorněn obraz v odstínech šedi s histogramem, histogram po ekvalizaci a jeho výsledný obraz [23].


Pro zlepšení obrazu se nejčastěji používá lineární transformační funkce, jejíž rovnice je následující

$$s = kr + q, \quad (15)$$


kde s je hodnota pixelu po zpracování, k je směrnice přímky, r je hodnota pixelu před zpracováním a q je posun přímky [23].




a)



b)




c)




d)

Obr. 9 Obrazy a jejich histogramy: a) šedotónový obraz, b) histogram šedotónového obrazu, c) šedotónový obraz po ekvalizaci histogramu, d) histogram po ekvalizaci.

Změnou q je docíleno zvýšení či snížení jasu a změnou k je dosaženo zvýšení či snížení kontrastu. Na obr. 10a) je znázorněn původní obraz tkaniny v odstínech šedi a na obr. 10b) je tentýž obraz, ale po zvýšení kontrastu ($k = 1$, $q = 70$).



a)



b)

Obr. 10 Zvýšení kontrastu v obraze: a) původní obraz v odstínech šedi, b) obraz získán zvýšením kontrastu ($k=1$, $q=70$).

3.2.2 Filtrace v prostorové oblasti

Na rozdíl od bodových jasových transformací filtrace v prostorové oblasti pracují s okolím pixelu v obraze a využívají se např. k odstraňování šumu a k ostření obrazu. Filtrace je soubor transformací obrazu převádějící hodnoty jasu vstupního obrazu na jiné hodnoty jasu výstupního obrazu. Cílem filtrace je zvýraznit nebo potlačit některé vlastnosti obrazu. Proces zahrnuje posuv počátku okolí z pixelu do pixelu, kde je aplikován operátor T na pixely v okolí dle vztahu (14).

Příkladem je lineární prostorová filtrace s okolím 3×3 , kde v každém bodě obrazu (x,y) odezva filtru $g(x,y)$ je suma součinů koeficientů filtru a obrazových bodů v daném okolí

$$g(x,y) = w(-1,-1)f(x-1,y-1) + w(-1,0)f(x-1,y) + \dots + w(0,0)f(x,y) + \dots + w(1,1)f(x+1,y+1), \quad (16)$$

kde počátek filtru $w(x,y)$ je v místě obrazového bodu $f(x,y)$ [23].

Podle účelu se metody lokálního předzpracování dělí do dvou skupin: vyhlazování a detekce hran [24].

Jedním z příkladů je vyhlazovací filtr, který slouží k rozostření, rozmazání obrazu a k potlačení šumu v obraze. Procesem rozostření se odstraňují malé detaily z obrazu před extrakcí velkých objektů. Každému bodu je přiřazen nový jas, který je průměrem původních jasů ve zvoleném okolí. Čím je na obraz použita větší velikost filtru, tím je obraz více rozmazán. Průměrovací filtr (viz obr. 11) se používá k potlačení nežádoucího šumu nebo detailu.

	1	1	1
1/9	1	1	1
	1	1	1

Obr. 11 Průměrovací filtr - velikost 3×3 .

Dalším příkladem je Gaussův filtr, který slouží k odstranění šumu v obraze a Laplacián, který se používá pro zvýraznění hran a k ostření obrazu.

Je možnost použít i nelineární filtrace, které jsou založeny na pořádkových statistikách. Jedná se o robustní odhad, to znamená, že vybočující hodnota neovlivňuje výsledek. Zde je příkladem mediánová filtrace, která se používá k redukci šumu s názvem „sůl a pepř“ [23].

Po operacích v rámci předzpracování obrazu sloužící ke zlepšení nasnímaného obrazu je obraz připraven na segmentaci.

3.3 Segmentace obrazu

V tomto kroku jsou v obraze nalezeny objekty, které jsou důležité pro další zpracování, jako je např. prahování, detekce bodů, přímk a hran [23].

3.3.1 Prahování

Prahování je nejčastější používanou operací v segmentaci obrazu. Vstupem je obraz v odstínech šedi (viz obr. 12a) a výstupem je obvykle binární obraz (viz obr.12d). Pokud je histogram obrazu tvořen dvěma dominantními vrcholy (viz obr. 12c), odseparují se pomocí prahu R a poté platí

$$g(x,y) = \begin{cases} 1 & \text{jestliže } f(x,y) > R \\ 0 & \text{jestliže } f(x,y) \leq R, \end{cases} \quad (17)$$

kde $g(x,y)$ je výstupní obraz, $f(x,y)$ je vstupní obraz a R je stanovený práh [23].

Úspěšnost prahování závisí na vzdálenosti mezi vrcholy v histogramu, čím dále jsou od sebe, tím jsou lépe odseparovány. Dalšími ovlivňujícími faktory jsou obsah šumu v obraze, relativní velikost objektů vůči pozadí, rovnoměrnost zdroje nasvícení a rovnoměrnost vlastností odrazivosti objektů [23].

Pokud se v obraze nachází více typů světlých objektů, použije se víceúrovňové prahování (např. dva prahy). Poté se prahování řídí dle následujícího vztahu

$$g(x,y) = \begin{cases} a & \text{jestliže } f(x,y) > R_2 \\ b & \text{jetliže } R_1 < f(x,y) \leq R_2 \\ c & \text{jestliže } f(x,y) \leq R_1, \end{cases} \quad (18)$$

kde $g(x,y)$ je výstupní obraz, $f(x,y)$ je vstupní obraz a R_1 je první práh a R_2 je druhý práh [23].

Jedním ze způsobu prahování je globální prahování, při kterém je R konstanta a je použita pro celý obraz. Pro odhad R lze použít automatický odhad, jehož algoritmus je následující:

1. počáteční odhad globálního prahu R_0 , který odpovídá průměrné úrovni šedi,
2. vytvoření dvou skupin pixelů podle

$$\begin{aligned} G_1 \text{ jestliže } \text{pixel} > R, \\ G_2 \text{ jestliže } \text{pixel} \leq R, \end{aligned} \quad (19)$$

3. vypočítání průměrné úrovně šedi m_1 a m_2 pro pixely ve skupině G_1 a G_2 ,
4. zjištění nové hodnoty globálního prahu R podle vztahu

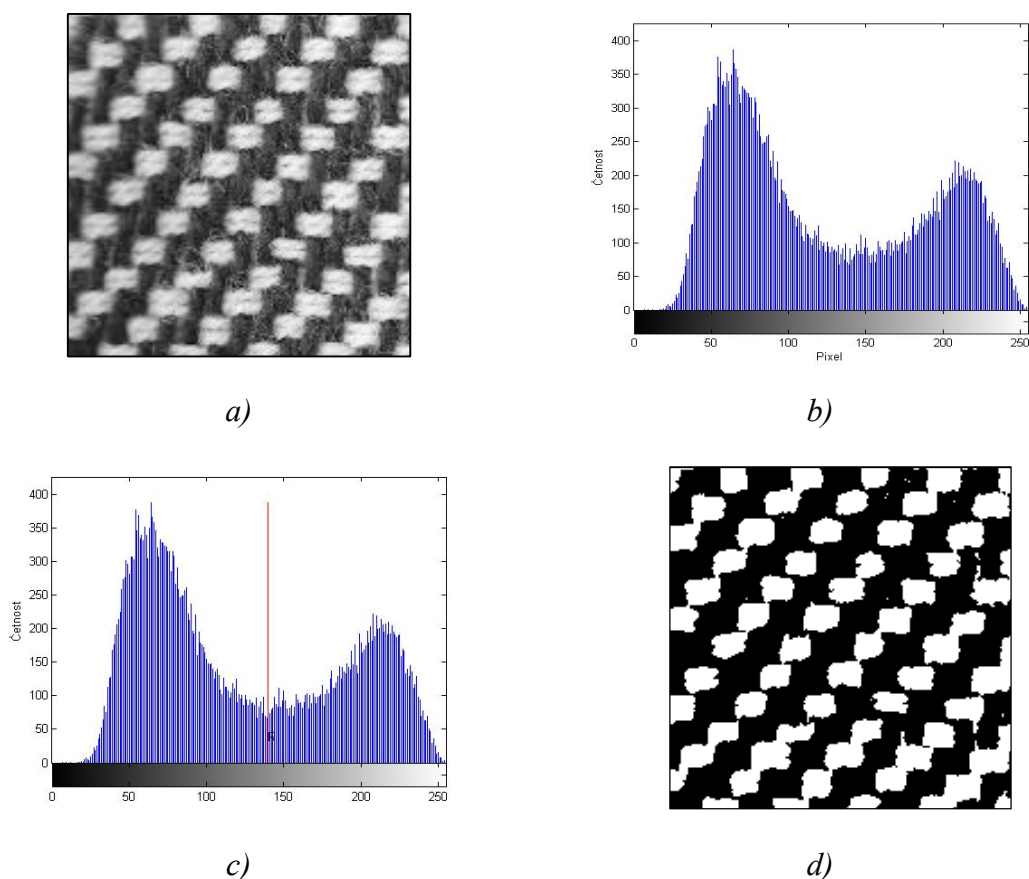
$$R = 0,5(m_1 + m_2), \quad (20)$$

5. opakování kroku 2. - 4. dokud rozdíl ΔR není menší než předvolená hodnota.

Algoritmus pracuje dobře, pokud jsou zřetelná údolí mezi módy histogramu [23].

Na obr. 12b) je zobrazen histogram tkaniny v odstínech šedi tvořen dvěma vrcholy představující světlé a tmavé nitě. Na obr. 12c) je zobrazena prahová hodnota R , podle které bylo provedeno prahování.

Pokud se hodnota R mění v ploše obrazu, operace se nazývá lokální (oblastní) prahování. Základními faktory jsou šum v obraze a nerovnoměrné nasvícení. Hlavní obraz je rozdělen do nepřekrývajících se částí, v nichž je vytvořen globální práh, pomocí kterého je provedeno prahování [23].



Obr. 12 Prahování obrazu: a) vstupní obraz v odstínech šedi, b) histogram, c) zobrazení prahové hodnoty $R=140$, d) výstupní binární obraz.

3.3.2 Houghova transformace

Pomocí Houghovy transformace se v obraze provádí detekce jednoduchých objektů, jako jsou např. přímky, kružnice nebo elipsy. Vstupem je binární obraz získán např. hranovým operátorem, prahováním nebo morfologiemi. Objekty jsou definované v parametrickém směru. Směrnice tvar přímky je

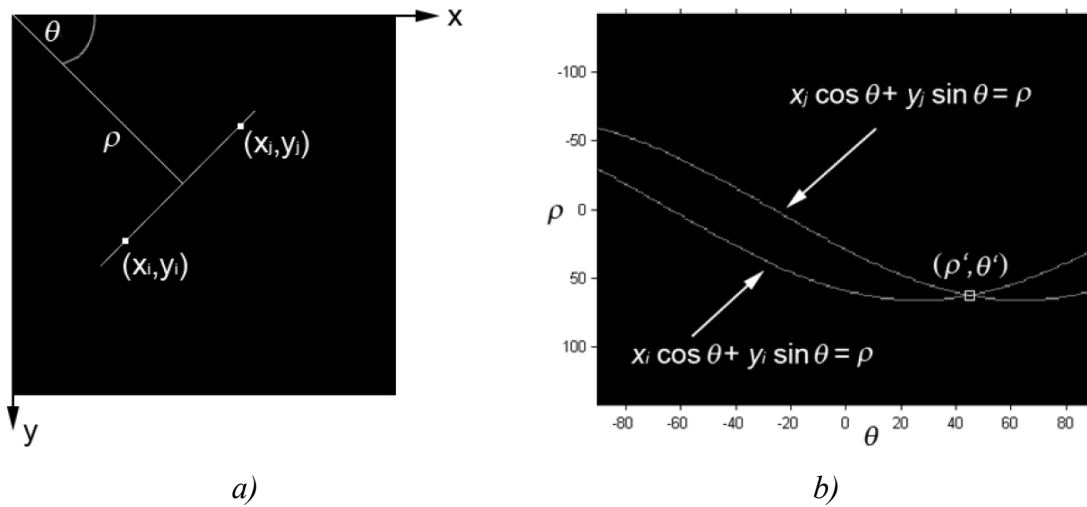
$$y = kx + q, \quad (21)$$

kde x a y jsou souřadnice bodu, k je směrnice přímky a q je posun přímky [23].

Když je přímka ve vertikálním směru, blíží se její směrnice k k nekonečnu, proto se používá normálový tvar rovnice přímky

$$\rho = x \cos \theta + y \sin \theta, \quad (22)$$

kde ρ je délka normály od přímky k počátku souřadnic a θ je úhel mezi normálou a osou x [23].




Obr. 13 Houghova transformace dle [28]: a) xy - prostor, b) $\rho\theta$ - prostor.

Na obr. 13a) je binární obraz, na kterém jsou zobrazeny dva body (x_i, y_i) a (x_j, y_j) , normála od přímky k počátku souřadnic ρ a úhel θ mezi normálou a osou x . Každá sinusová křivka na obr. 13b) reprezentuje přímky procházející bodem (x, y) . Průsečík (ρ', θ') z obr. 13b) odpovídá přímce procházející body (x_i, y_i) a (x_j, y_j) na obr. 13a) [23].

Pro detekci přímek se používá tzv. akumulátor, jedná se o dvojrozměrný graf, kde na jedné ose je vynesena úhel θ a na druhé ose je vzdálenost ρ . Pro každý pixel zájmu, tj. objektový pixel $f(x, y) = 1$, je vypočtena hodnota ρ_j podle vztahu (16) a je zvýšena hodnota akumulátoru. Po průchodu celým obrazem jsou v akumulátoru hodnoty n_{ij} , které určují počet nalezených bodů ležících na přímce dané parametry (θ_i, ρ_j) . Nejvyšší hodnota n_{ij} určuje parametry (θ_i, ρ_j) přímky, na které se nachází nejvíce bodů v obraze (viz obr. 14) [23].

Na obr. 14b) je vidět, že velikost úhlu θ se pohybuje v rozmezí 25° - 65° , tzn., že nalezené přímky v obraze mají přibližně stejný sklon (viz obr. 14a) a 14b).




Obr. 14 Hledání přímek v obraze dle [28]: a) binární obraz, b) akumulátor, c) nalezené přímky.

3.4 Popis nalezených objektů

Z obrazu se dají dopočítat různé číselné charakteristiky (např. plocha a obvod objektů) nebo lze zjistit vztahy mezi objekty (např. sousednost a vzdálenost). Vybrané z nich jsou popsány níže [23].

3.4.1 Sousednost


Rozlišují se dva základní typy sousednosti: 4-sousednost (viz obr. 15a), kde pixel má čtyři sousední body a 8-sousednost (viz obr. 15b) s osmi sousedními body.



Obr. 15 Příklady sousednosti dle [29]: a) 4-sousednost, b) 8-sousednost.

3.4.2 Vzdálenost mezi pixely

Vzájemné vzdálenosti mezi jednotlivými pixely lze zjistit třemi různými způsoby (viz obr. 16) [23].



Obr. 16 Vzdálenosti mezi pixely.

Euklidovská vzdálenost mezi body X a Y

Tato vzdálenost je popsána následujícím vztahem

$$D_e(X, Y) = \sqrt{(y_2 - y_1)^2 + (x_2 - x_1)^2}, \quad (23)$$

kde x_1 a y_1 jsou souřadnice jednoho bodu a x_2 a y_2 jsou souřadnice druhého bodu.

Nevýhodou této metody je neceločíselná výsledná hodnota.

Vzdálenost v městských blocích

Je to nejmenší počet kroků jednotkové vzdálenosti mezi dvěma body v pravoúhlé diskretizační mřížce. Lze dělat pouze kroky o jedno pole v mřížce ve vodorovném nebo ve svislém směru.

Šachovnicová vzdálenost

V případě použití šachovnicové vzdálenosti lze dělat kroky o jedno pole ve všech směrech (horizontální, vertikální, diagonální).

3.5 Porozumění obsahu obrazu

V tomto kroku se klasifikují objekty v obraze do skupin podle jejich společných znaků [23], tímto se ale práce nezabývá.

Veškeré výše uvedené operace jsou použity v algoritmu.

4. SADA VZORKŮ

Pro experimentální část byly zvoleny vícebarevné tkaniny ze 100% polyesteru, nebo ze 100% bavlny v plátňové, nebo keprové vazbě. Popis vzorků tkanin je zobrazen v následující tabulce.







Tab. 1 Popis vzorků tkanin.


Vzorek	Složení	Vazba	Počet barevných nití	
			osnova	útek
P1	polyester	plátňo	1	1
P2	polyester	plátňo	1	1
P3	polyester	plátňo	1	1
P4	polyester	plátňo	2	1
P5	polyester	plátňo	2	1
P6	polyester	plátňo	2	1
P7	polyester	plátňo	2	1
P8	polyester	plátňo	2	1
P9	polyester	plátňo	2	2
P10	polyester	plátňo	2	2
P11	polyester	plátňo	2	2
P12	polyester	plátňo	2	2
K1	bavlna	kepr	1	1
K2	bavlna	kepr	1	1
K3	bavlna	kepr	1	1
K4	bavlna	kepr	1	1
K5	bavlna	kepr	1	1
K6	bavlna	kepr	1	1

4.1 Pořízení obrazu

Obrazy tkanin P1 – P12 (viz obr. 17) byly pořízeny na mikroskopu OLYMPUS BX51 s horním nasvícením a uloženy prostřednictvím programu QuickPHOTO CAMERA 2.3 s rozlišením 1360×1024 px. Obrazy K1 – K6 (viz obr. 16) byly pořízeny fotoaparátem Canon EO400D s rozlišením 2592×3888 px, při snímání byl použit objektiv.

Všechny obrazové operace byly provedeny s využitím IPT (image processing toolbox), který obsahuje funkce týkající se zpracování obrazu v programu MATLAB, použité algoritmy jsou uvedeny v příloze. Byly testovány s rozlišením 500×500 px, reálná velikost obrazů pořízených mikroskopem byla $7,01 \times 7,01$ mm ($1 \text{ px} = 0,01402$ mm) a obrazy pořízené fotoaparátem měly reálnou velikost $3,23 \times 3,23$ mm ($1 \text{ px} = 0,00645$ mm).

*a)**b)**c)**d)**e)**f)*



Obr. 17 Sada vzorků: a) P1, b) P2, c) P3, d) P4, e) P5, f) P6, g) P7, h) P8, i) P9, j) P10, k) P11, l) P12, m) K1, n) K2, o) K3, p) K4, q) K5, r) K6.

5.1.1 Stanovení vazných bodů

V této části bylo potřeba stanovit, kde jsou v obraze nitě a kde jsou mezery mezi nimi. Proto byl pořízený barevný obraz v modelu RGB převeden do šedotónového pomocí zaimplementované funkce *rgb2gray*, která sčítá hodnoty v jednotlivých kanálech násobené váhovými koeficienty.

$$\text{Šedotónový obraz z RGB obrazu} = 0,29 \times R + 0,59 \times G + 0,12 \times B, \quad (24)$$

kde R je intenzita červeného kanálu, G je intenzita zeleného kanálu a B je intenzita modrého kanálu [23].

Jeden pixel v šedotónovém obraze se skládá z 256 odstínů šedi (0-255), kde 0 znázorňuje černou barvu a 255 bílou. Kvůli malým rozdílům mezi světlými a tmavými odstíny se provedla ekvalizace histogramu prostřednictvím zaimplementované funkce *histeq*, která rozdíly více zviditelnila.

Z šedotónového obrazu byly vykresleny průměrné profily osnovy a útku, které znázorňují průměrné úrovně šedi zjištěné po řádcích a po sloupcích. Průměrná hodnota šedi ve směru osnovy byla zjištěna dle vztahu [3]

$$G_o(i) = \frac{\sum_{j=1}^N f(x, y)}{N},$$
$$i = 1, 2, 3, \dots, M,$$
$$j = 1, 2, 3, \dots, N$$
(25)


kde i je řádek, N je počet sloupků, $f(x, y)$ je intenzita pixelu a j je sloupek.

Průměrná hodnota šedi ve směru útku byla zjištěna dle vztahu [3]

$$G_u(j) = \frac{\sum_{i=1}^M f(x, y)}{M},$$
$$i = 1, 2, 3, \dots, M,$$
$$j = 1, 2, 3, \dots, N,$$
(26)


kde j je sloupek, M je počet řádků, $f(x, y)$ je intenzita pixelu a i je řádek.

Zjištěné hodnoty z obr. 18c) byly zaneseny do grafů. Na obr. 19 jsou vidět průměrné profily osnovy a útku, které mají periodický průběh. Vysoké hodnoty v grafu, světlé odstíny z obr. 18c), představují nitě a nízké hodnoty v grafu, tmavé odstíny z obr. 18c), mezery mezi nimi.




Obr. 19 Profil osnovy a útku bez vyhlazení dat.

Pro identifikaci vazných bodů je potřeba nejprve nalézt mezery mezi nitěmi, které se v grafu nacházejí na místech lokálních minim.



a)



b)

Obr. 20 Nalezení mezer mezi nitěmi: a) znázorněná minima v grafu, b) vykreslení mříže do obrázku.

Na obr. 20a) jsou červenými kroužky znázorněna nalezená minima. Z obr. 20b) je patrné, že byl nalezen větší počet minim, než se očekávalo. Z tohoto důvodu bylo potřeba profil vyhladit, jedna z možností je použití metody klouzavého průměru s určitým okolím. Pro průměrný profil osnovy byl použit vztah

$$PK_O = \frac{\left(f(x, y)_{i-\frac{filtr-1}{2}} + \dots + f(x, y)_{i-1} + f(x, y)_i + f(x, y)_{i+1} + \dots + f(x, y)_{i+\frac{filtr-1}{2}} \right)}{filtr}$$

$$i = \frac{filtr + 1}{2}, \dots, N - \frac{filtr - 1}{2}, \quad (27)$$

kde $f(x, y)$ je hodnota pixelu, i je řádek a $filtr$ je velikost okolí.

Obdobným způsobem byl vyhlazen průměrný profil útku

$$PK_U = \frac{\left(f(x, y)_{j-\frac{filtr-1}{2}} + \dots + f(x, y)_{j-1} + f(x, y)_j + f(x, y)_{j+1} + \dots + f(x, y)_{j+\frac{filtr-1}{2}} \right)}{filtr}$$

$$j = \frac{filtr + 1}{2}, \dots, N - \frac{filtr - 1}{2}, \quad (28)$$

kde $f(x, y)$ je hodnota pixelu, j je sloupek a $filtr$ je velikost okolí. Pro obr. 18c) byla použita velikost okolí 15 pixelů pro obě soustavy nití ($filtr = 15$).

Průběh funkce na obr. 21 odpovídá tkanině na obr. 18c). Pro nalezení lokálních minim ve směru osnovy, která představují mezery mezi nitěmi, byl použit vztah

$$U = f(x, y)_{i-\frac{okolí}{2}} \geq \dots \geq f(x, y)_{i-1} \geq f(x, y)_i \leq f(x, y)_{i+1} \leq \dots \leq f(x, y)_{i+\frac{okolí}{2}}, \quad (29)$$

$$i = 1, 2, 3, \dots, M,$$


kde $f(x,y)_i$ je hodnota aktuálního pixelu, která musí být nejnižší ve stanoveném okolí, $okoli$ je velikost okolí, ve kterém se hledá lokální minimum, i je řádek a M je počet řádků v obraze.

Lokální minima ve směru útku byla nalezena vztahem

$$U = f(x, y)_{j-\frac{okoli}{2}} \geq \dots \geq f(x, y)_{j-1} \geq f(x, y)_j \leq f(x, y)_{j+1} \leq \dots \leq f(x, y)_{j+\frac{okoli}{2}},$$


$$j = 1, 2, 3, \dots, N$$

kde $f(x,y)_j$ je hodnota aktuálního pixelu, která musí být nejnižší ve stanoveném okolí, $okoli$ je velikost okolí, ve kterém se hledá lokální minimum, j je sloupek a N je počet sloupků v obraze.




Obr. 21 Průměrné profily vyhlazeny klouzavým průměrem ($filtr = 15$) dle vztahu (27) a (28).

Dle vztahu (29) a (30) byly do obr. 22 červenými kroužky vykresleny lokální minima odpovídající mezerám mezi nitěmi z obr. 18c).



Obr. 22 Lokální minima vyhlazených profilů představující mezery mezi nitěmi.

Na obr. 23 jsou zakreslena lokální minima, která byla nalezena pomocí vztahu (29) a (30). Svislé červené čáry představují lokální minima nalezená ve směru útku a žluté horizontální čáry lokální minima ve směru osnovy. Mříží vzniklo několik oblastí odpovídající nalezeným vazným bodům.



Obr. 23 Zakreslení nalezených lokálních minim do obrazu RGB.

Pro správné vyhodnocení profilů osnovy a útku musí být obraz v odstínech šedi, osnova musí mít horizontální směr a útkem vertikální a zároveň musí spolu svírat úhel 90° , dále musí být správně nastavena velikost okolí pro výpočet lokálních minim a maxim. Při nesplnění alespoň jedné podmínky účinnost algoritmu klesá.


5.1.2 Stanovení počtu barev

Při rekonstrukci není předem známo, kolik testovaná tkanina obsahuje barev. Tento faktor je pro další zpracování velmi důležitý, proto v každém vazném bodě V_p ($p = 1, 2, 3, \dots, v$) byla vypočtena průměrná barva tak, že byl vypočten průměr každého kanálu individuálně, vyjádřeno vztahem

$$f_V(\bar{R}, \bar{G}, \bar{B}) = \left[\frac{\sum_{l=1}^n R_l}{n} \quad \frac{\sum_{l=1}^n G_l}{n} \quad \frac{\sum_{l=1}^n B_l}{n} \right], \quad (31)$$

$$l = 1, 2, 3, \dots, n$$

kde n je počet pixelů v obraze, R_l je intenzita červeného kanálu aktuálního vazného bodu V_p , G_l je intenzita zeleného kanálu, B_l je intenzita modrého kanálu a v je počet vazných bodů v obraze.




Obr. 24 Oblast pro výpočet průměrné barvy vazného bodu: a) vazný bod, b) zmenšená oblast.

Může se stát, že z důvodu chlupatosti přízí nebo nepřesného vykreslení mříže v obraze oblast představující vazný bod neobsahuje pouze barvu nitě osnovy či útku, ale i barvu druhé soustavy nití (viz obr. 24a). V levém horním a v pravém spodním rohu oblasti zasahuje do světle zeleného vazného bodu tmavě zelené nitě z okolních vazných bodů.

Jednou z možností je zmenšit oblast V pro výpočet průměrné barvy o stejnou vzdálenost (parametr *vzdálenost*) ze všech stran (viz obr. 24b). Vypočtené průměrné barvy jednotlivých vazných bodů z obr. 23 byly zapsány v tab. 2 a následně vykresleny do nového obr. 25, který obsahuje pouze celé vazné body.


Tab. 2 Průměrné barvy vazných bodů z obr. 23.

V	\bar{R}	\bar{G}	\bar{B}	V	\bar{R}	\bar{G}	\bar{B}
1	140,40	189,87	56,99	16	98,97	99,46	26,76
2	95,31	87,79	24,43	17	101,89	139,82	35,91
3	127,34	173,24	46,49	18	86,30	77,78	21,96
4	100,36	89,46	25,88	19	91,79	83,54	23,02
5	117,58	159,97	41,71	20	119,11	154,84	39,28
6	91,51	85,79	24,15	21	86,87	77,41	22,92
7	95,80	88,30	24,30	22	114,19	155,09	40,90
8	142,71	191,09	55,65	23	77,88	69,52	20,79
9	93,38	86,38	24,20	24	98,94	127,80	31,39
10	123,76	166,84	43,55	25	113,91	157,98	41,14
11	88,49	79,63	23,28	26	81,99	76,34	21,21
12	132,23	175,84	46,61	27	99,91	128,89	33,38
13	116,21	159,14	42,74	28	82,16	74,44	21,32
14	88,23	83,07	22,86	29	99,35	139,50	36,92
15	111,78	156,64	42,22	30	74,34	69,90	19,42



Obr. 25 Vykreslení průměrných barev vazných bodů.

Dále byl z průměrných hodnot v tab. 2 vytvořen 3D graf znázorňující počet barev ve tkanině (viz obr. 26), kde jednotlivé osy představují intenzitu červeného, zeleného a modrého kanálu. Každý malý shluk v grafu představuje jednu oblast z obr. 25. Na obrázku jsou znázorněny dvě průměrné barvy odpovídající dvěma shlukům.




Obr. 26 3D graf.

Může nastat situace, kdy jednoznačně nelze určit jednotlivé shluky (barvy). Proto byla do algoritmu přidána metoda hierarchického shlukování, pomocí které byly jednotlivé shluky odděleny.

Hierarchické shlukování

Shlukování je založeno na postupném spojování nebo dělení objektů. Divizní metoda (dělení objektů) postupně rozdělí jeden velký shluk všech objektů na K shluků obsahující jeden objekt. Dělení probíhá na základě vzdálenosti jednotlivých bodů. Vypočítají se vzájemné vzdálenosti dvou bodů všech možných kombinací. Ty, které mají vzdálenost nejbližší, se spojí v jeden. Aglomerační metoda (spojování objektů) je


opak divizní metody, z K shluků vznikne jeden shluk postupným spojováním dvou nejpodobnějších shluků. Výsledný graf se nazývá dendrogram (viz obr. 27) [26].



Obr. 27 Dendrogram.

Na ose x jsou vykresleny jednotlivé shluky (průměrná barva zmenšeného vazného bodu) a na ose y jsou vyjádřeny vzdálenosti vždy mezi dvěma shluky. Např. vzdálenost mezi shlukem č. 21 a č. 25 je 5 pixelů, vzdálenost mezi červeně označenými daty a zeleně označenými daty je zhruba 17 pixelů. Dále lze z dendrogramu vyčíst, že data byla původně rozdělena do tří shluků (červeně, zeleně a modře vyznačeny). Nejprve se spojila červená data se zelenými, tím vznikly dva shluky (červená data se zelenými a modrá data). Na závěr vznikl jeden velký shluk skládající se z modrých dat a z již spojených červených a zelených dat.

V experimentu byla použita aglomerační metoda, avšak neprokázala se jako ideální. Tato metoda ze všech dat vytvoří vždy jeden výsledný shluk. V práci je ale potřeba, aby pomocí metody byl nalezen správný počet shluků. Toho lze dosáhnout použitím stanoveného prahu, který by výsledný dendrogram prořízl (viz obr. 28) a vznikl by potřebný počet shluků. Vzhledem k tomu, že se nedá nastavit automatický práh, který by daný dendrogram uřízl tak, aby vznikl potřebný počet shluků, byla v práci použita shlukovací metoda K -průměrů.



Obr. 28 Dendrogram s prahem.

Shlukování K-means (K-průměrů)

Tato metoda se nejčastěji používá pro vytváření malého počtu shluků z velkého počtu dat. Cílem shlukování je rozdělit data do K shluků tak, že suma čtverců vzdáleností pozorování od těžiště uvnitř shluku je minimální. Nevýhodou této metody je, že se předem musí určit počet shluků K , které mají být nalezeny. Postup je rozdělen do dvou kroků, nejprve je objekt přiřazen do nejbližšího shluku, s využitím Eukleidovské vzdálenosti mezi pozorováním a těžištěm shluku. Poté jsou přepočteny těžiště jednotlivých shluků. Proces se opakuje, dokud není dosaženo nejmenší mezishlukové sumy čtverců vzdálenosti souřadnic pozorování od těžiště, vyjádřeno následujícím vztahem

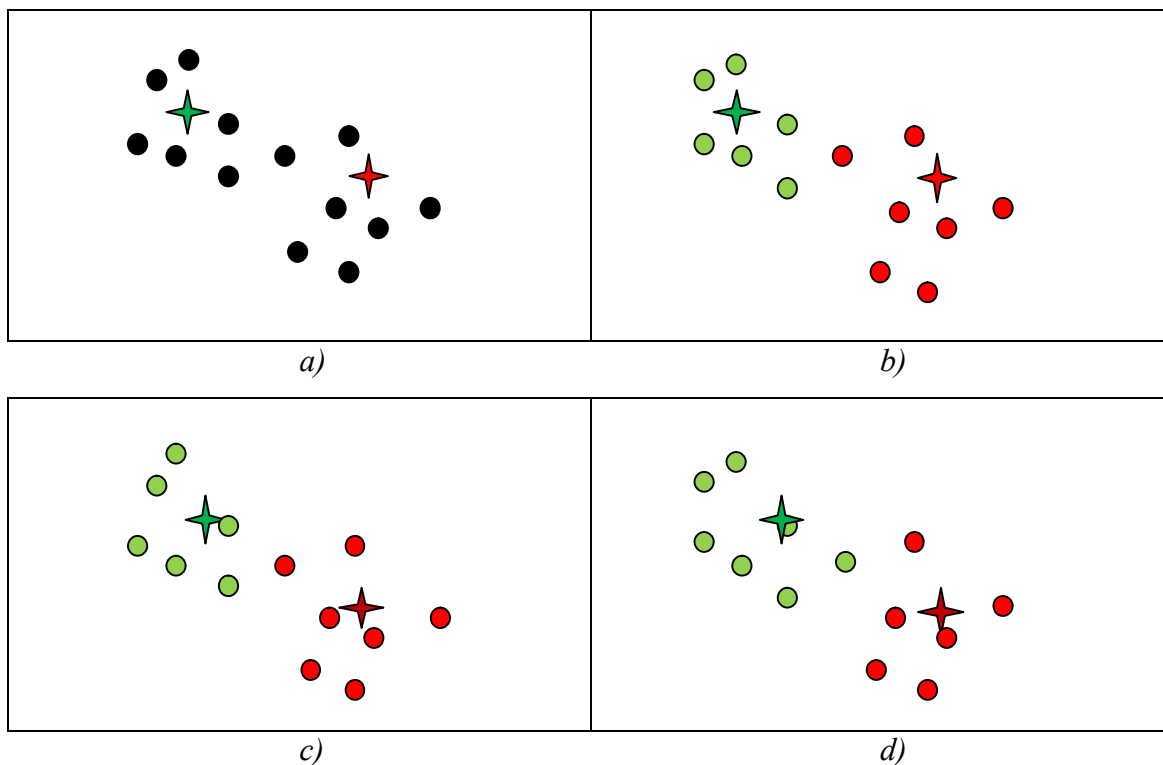
$$M = \sum_{i=1}^k \sum_{x_j \in S_i} (x_j - \mu_i)^2, \quad (32)$$

kde μ_i je těžiště shluku S_i a x_j jsou data pozorování z 3D grafu [26], [27].

Algoritmus pro stanovení shluků je následující [26]:

1. stanovení počtu shluků,
2. určení výchozích středů (těžiště) shluků (náhodně vybrané),
3. vypočítání vzdálenosti mezi objektem a těžištěm,
4. přiřazení každého objektu nejbližšímu shluku na základě Euklidovské vzdálenosti,

5. vypočtení aktuálních středů (těžišť) nových shluků,
6. opakování kroků 2-5, dokud není dosaženo nejmenší mezishlukové sumy čtverců.



Obr. 28 Schéma algoritmu K -průměrů: a) rozložení dat, b) přiřazení dat do shluků, c) vypočítání nových těžišť, d) přiřazení dat do nových shluků.


Na obr. 28 je znázorněn průběh algoritmu. Nejprve byla vykreslena pozorování s náhodně zvolenými těžišti (tmavě červené a tmavě zelené hvězdy). Na obr. 29b) byla jednotlivá pozorování přiřazena do shluku podle nejmenší Euklidovské vzdálenosti. Světle zelené tečky byly přiřazeny k tmavě zelenému těžišti a světle červené tečky k tmavě červenému těžišti. Na obr. 29c) byla vypočtena nová těžiště podle vzniklých shluků (posunutí tmavých teček) a na závěr na obr. 29d) byla opět data přiřazena do nových shluků v závislosti na Euklidovské vzdálenosti od nového těžiště (změna jedné červené tečky na zelenou barvu).

Výsledný graf zobrazuje siluety jednotlivých shluků. Graf siluet zobrazuje míru, jak jsou blízko body v jednom shluku vzhledem k ostatním shlukům. Míra se pohybuje v rozmezí $(-1; 1)$. Míra 1 indikuje, že body jsou velmi vzdálené od sousedních shluků a

míra (-1) indikuje, že body jsou pravděpodobně přiřazené do správného shluku. Míra podobnosti je definována vztahem

$$S(i) = (\min(d(i, :), 2) - c(i)) / \max(c(i), \min(d(i, :))), \quad (33)$$


kde $c(i)$ je průměrná vzdálenost i -tého bodu od dalšího bodu v jednom shluku a $d(i, k)$ je průměrná vzdálenost i -tého bodu od dalšího bodu v jiném shluku [27].



Obr. 30 Siluety pro tři shluky.

Vztah (26) je graficky znázorněn na obr. 30. Druhý shluk má svá data velmi dobře oddělitelná od zbývajících shluků, protože jejich hodnota je vyšší než 0,8. Všechna data z prvního shluku jsou velmi špatně rozpoznatelná, jejich hodnoty rostou od záporných hodnot a nedosáhnou hodnoty vyšší jak 0,8. Většina dat ze třetího shluku jsou dobře rozpoznatelná od ostatních shluků, protože jejich hodnoty se blíží k hodnotě 1. Zbývající data mají nižší hodnotu, proto se špatně oddělují od zbylých dvou shluků.

Na obr. 31 je znázorněn graf siluet dvou shluků představující jednotlivé barvy, které vznikly použitím shlukovací metody K-průměrů.



Obr. 31 Siluety pro dva shluky.

Siluetní shluky na obr. 31 znázorňují, jak si jsou data v jednom shluku podobná s daty z druhého shluku. Data blízké k hodnotě 1 jsou snadno rozlišitelná od dat z druhého shluku. V tomto případě data z prvního shluku jsou dobře oddělená od druhého shluku. Většina dat z druhého shluku je také dobře oddělena, ale pár dat se nachází blízko prvního shluku, protože jejich hodnota je nižší než 0,8.


Tab. 3 Průměrné hodnoty z grafu siluet.

Počet shluků (barev)	Průměrná hodnota z grafu siluet
2	0,8671
3	0,7104
4	0,6904
5	0,6175
6	0,6305

Před použitím této metody musí být stanoven počet shluků, které mají být nalezeny. Vzhledem k tomu, že předem není známo, kolik daná tkanina obsahuje barev, je v práci vytvořen cyklus, ve kterém je za K (počet shluků) dosazeno číslo 2 až 6. Kvantitativní cestou pro porovnání, který součet shluků je správný, je vypočítání průměrných hodnot z grafu siluet a v nich nalézt maximum (viz tab. 3). Pro grafy siluet platí, čím jsou

shluky větší, tím je jejich průměr vyšší. Nejvyšší hodnota byla vypočtena pro $K = 2$, tzn., že tkanina pravděpodobně obsahuje dvě barvy.

Na obr. 32 jsou vyneseny nalezené barvy, které odpovídají těžištěm jednotlivých shluků.



Obr. 32 Tkanina ze dvou barev.

5.1.3 Stanovení hran mezi vaznými body

Pro vytvoření vzoru tkaniny bylo potřeba zjistit, zda vedle sebe v horizontálním či vertikálním směru leží dva osnovní, dva útkové nebo jeden osnovní a jeden útkový vazný bod. Myšlenka stanovení hrany je založena na tom, že pokud vedle sebe leží dva odlišné vazné body, bude odchylka na přechodu mezi body vysoká. Při stanovení hran se vycházelo z barveného obrazu RGB, ve kterém byla zjišťována velikost směrodatné odchylky pixelu. Směrodatná odchylka pixelu je počítána ze všech pixelů pomocí následujícího vztahu

$$S = \sqrt{\frac{\sum_{i=1}^l [(R_i + G_i + B_i) - f(\bar{R}, \bar{G}, \bar{B})]^2}{3l}}, \quad (34)$$


kde l je počet pixelů, R_i je intenzita červeného kanálu, G_i je intenzita zeleného kanálu, B_i je intenzita modrého kanálu a $f(\bar{R}, \bar{G}, \bar{B})$ je průměrná hodnota pixelu vypočtena ze všech kanálů. Protože se ve vzorci nejprve sečtou hodnoty červeného, zeleného a modrého kanálu (RGB), musí se číselník dělit třemi, proto je použito $3l$.

Pokud byla směrodatná odchylka pixelu větší než stanovený práh, byla v obraze vytvořena hrana mezi vaznými body, tzn., že vedle sebe se nachází jeden vazný bod osnovní a jeden útkový (viz obr. 34). Podmínky stanovení hrany jsou popsány následujícím vztahem


$$\begin{aligned} 0 \text{ není hrana když } S &\leq \text{prah}, \\ 1 \text{ je hrana když } S &> \text{prah}. \end{aligned} \quad (35)$$

kde S je směrodatná odchylka pixelu ze vztahu (40) a prah je stanovený práh.


Směrodatná odchylka pixelu byla počítána jen na přechodu mezi vaznými body (viz obr. 33), parametr *prechod* v obraze značí vzdálenost v pixelech od jednotlivých čar mříže. Pokud byla na přechodu identifikována hrana, je v obraze vyznačena černou čarou (viz obr. 35).



Obr. 33 Oblast pro výpočet směrodatné odchylky pixelu.



Obr. 34 Zjištění hran.



Obr. 35 Výsledný obraz tkaniny.

Po porovnání výsledného obrazu tkaniny s původním RGB obrazem lze metodu považovat za efektivní. Testovaná tkanina má plátňovou vazbu s rozdílnými barvami v osnově a útku. Výsledný obraz tkaniny obsahuje dvě barvy velmi blízké barevnému obrazu RGB. Mezi vaznými body jsou v obraze vytvořeny hrany, tzn., že tkanina je v plátňové vazbě.

5.2 Aplikace algoritmu na vzorky tkanin

V této podkapitole budou ukázány příklady několika tkanin, v případě nesprávně provedené rekonstrukce bude navržen vhodnější postup. Navržená posloupnost kroků byla realizována formou algoritmu, který byl realizován na barevné tkaniny s plátňovou a keprovou vazbou.

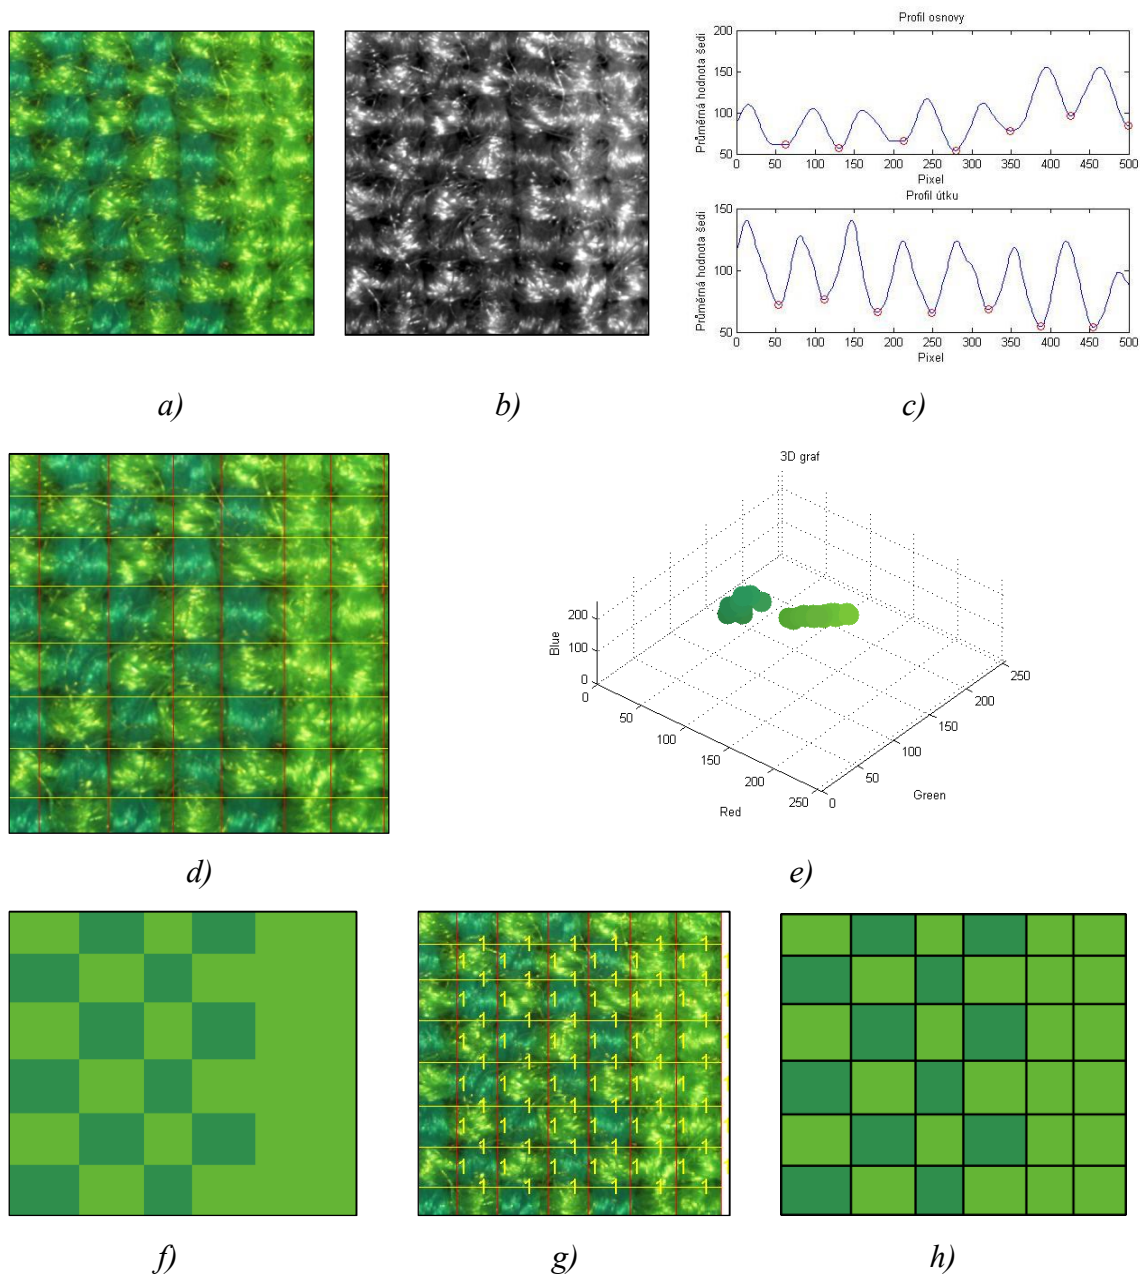
5.2.1 Vzorek P4

Jedním z testovaných vzorků byla plátňová tkanina ze dvou velmi podobných odstínů zelené barvy (dvě barvy v osnově a jedna barva v útku), na levé části obrazu se střídají dvě barvy, kdežto v pravé části je barva pouze jedna (viz obr. 36a).

Tab. 4 Průměrné hodnoty z grafu siluet pro tkaninu P4.

Počet shluků (barev)	Průměrná hodnota z grafu siluet
2	0,9186
3	0,7883
4	0,7345
5	0,7180
6	0,6896

Pomocí algoritmu bylo zjištěno, že nejvyšší průměrná hodnota byla zjištěna pro $K = 2$ (viz tab. 4). Tzn., že zkoumaný obraz tkaniny se skládá ze dvou barev. Výsledek odpovídá obr. 36e), kde jsou zřetelně odděleny jednotlivé shluky.



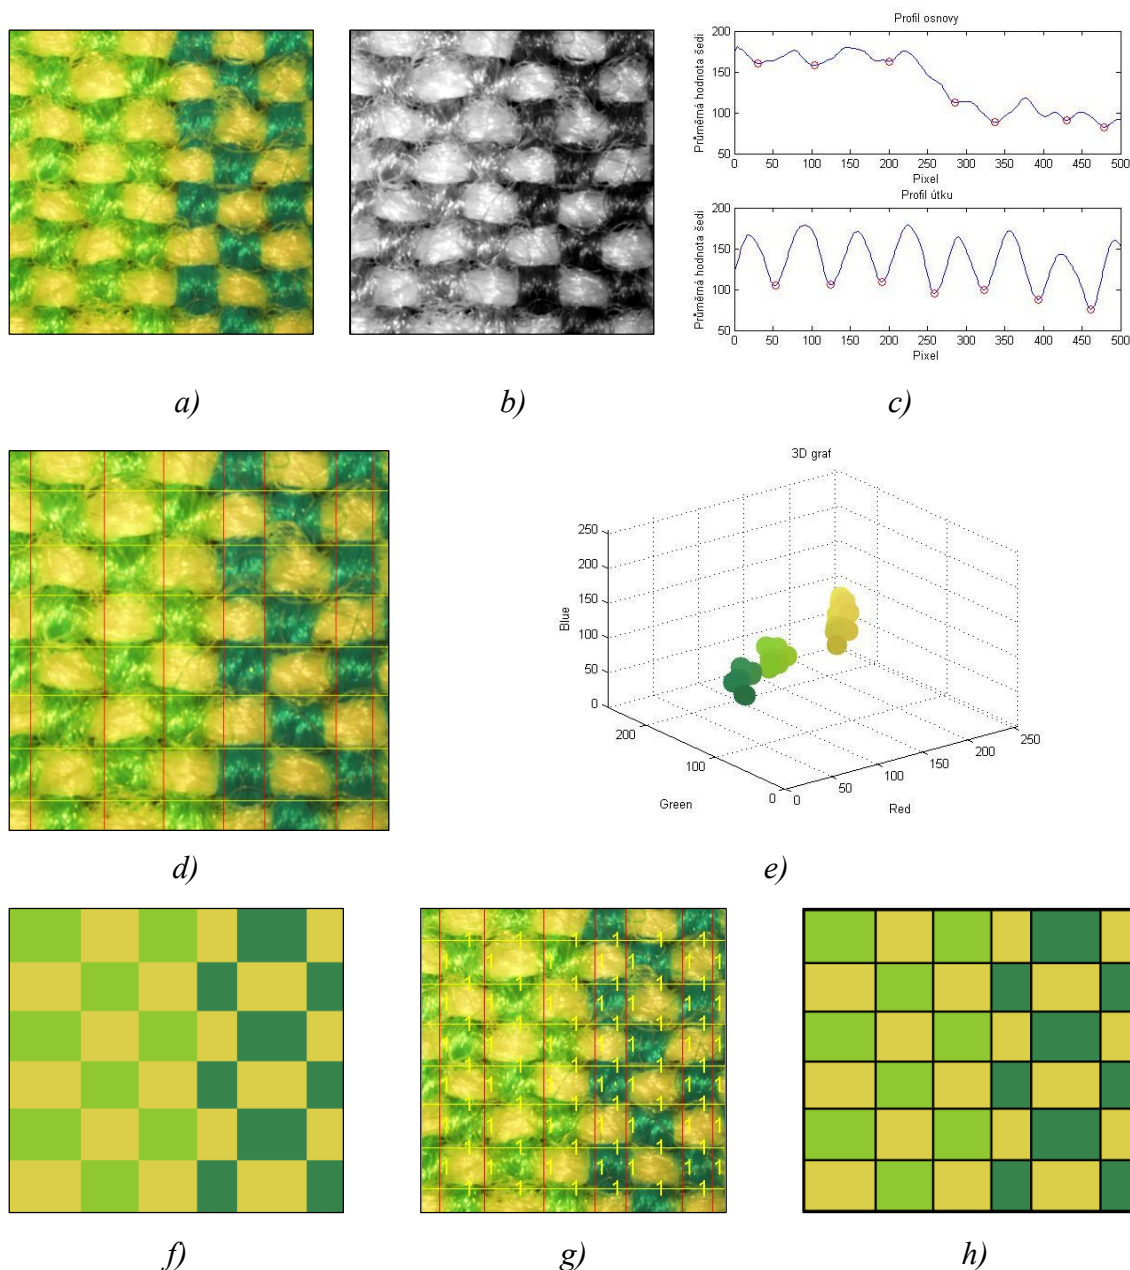
Obr. 36 Dvoubarevné plátno: a) vstupní obraz RGB, b) šedotónový obraz, c) profil osnovy a útku, d) mříž v tkanině, e) 3D graf, f) tkanina ze dvou barev, g) zjištění hran, h) výsledný obraz tkaniny.

Na obr. 36d) je vidět, že byly dobře identifikovány mezery mezi nitěmi, které závisí na parametru *filtr* a *okoli* (*filtr* = 15, *okoli* = 45). Na obr. 36e) jsou dobře od sebe odseparovány jednotlivé barvy (*vzdalenost* = 16), které byly následně zaneseny do nového obrazu. Na obr. 36h) jsou správně zakresleny hrany mezi vazné body (*prechod* = 20, *prah* = 8). Po srovnání výsledného obrazu s původním RGB obrazem je

vidět, že metodu lze použít i pro plátňové tkaniny skládající se z dvou podobných odstínů barev v osnově a v útku.

5.2.2 Vzorek P7

Následovala třibarevná tkanina plátňové vazby se dvěma barevnými nitěmi v osnově a jednou nití v útku, jejíž postup je znázorněn na obr. 37.



Obr. 37 Třibarevné plátno: a) vstupní obraz RGB, b) šedotónový obraz, c) profil osnovy a útku, d) mříž v tkanině, e) 3D graf, f) tkanina ze dvou barev, g) zjištění hran, h) výsledný obraz tkaniny.

Z obrazů je patrné, že algoritmem byly dobře identifikovány mezery mezi nitěmi ($\text{filtr} = 15$, $\text{okoli} = 45$), tzn., že byly správně identifikovány vazné body, což je patrné na obr. 37d). Dále byly správně nalezeny barvy v obraze ($\text{vzdalenost} = 16$), což ilustruje 3D graf na obr. 37e). Výsledky průměrných hodnot grafů siluet jsou zapsány v tab. 5. Hrany mezi vaznými body byly správně vytvořeny, což je vidět na obr. 37h) ($\text{prechod} = 20$, $\text{prah} = 8$).

Po vytvoření výsledného obrazu tkaniny je vidět, že metodu lze aplikovat i na plátňové tkaniny skládající se ze tří barev.

Tab. 5 Průměrné hodnoty z grafu siluet pro tkaninu P7.


Počet shluků (barev)	Průměrná hodnota z grafu siluet
2	0,8473
3	0,8986
4	0,8585
5	0,7864
6	0,7339

5.2.3 Vzorek P11

Další testovanou tkaninou bylo čtyřbarevné plátno (tři barevné nitě v osnově a dvě barevné nitě v útku), jehož průběh je znázorněn na obr. 38. V tab. 6 jsou zapsány průměrné hodnoty grafů siluet, které byly získány prostřednictvím shlukovací metody K-průměrů.

Tab. 6 Průměrné hodnoty z grafu siluet pro tkaninu P11.

Počet shluků (barev)	Průměrná hodnota z grafu siluet
2	0,5996
3	0,7920
4	0,9193
5	0,6749
6	0,6944

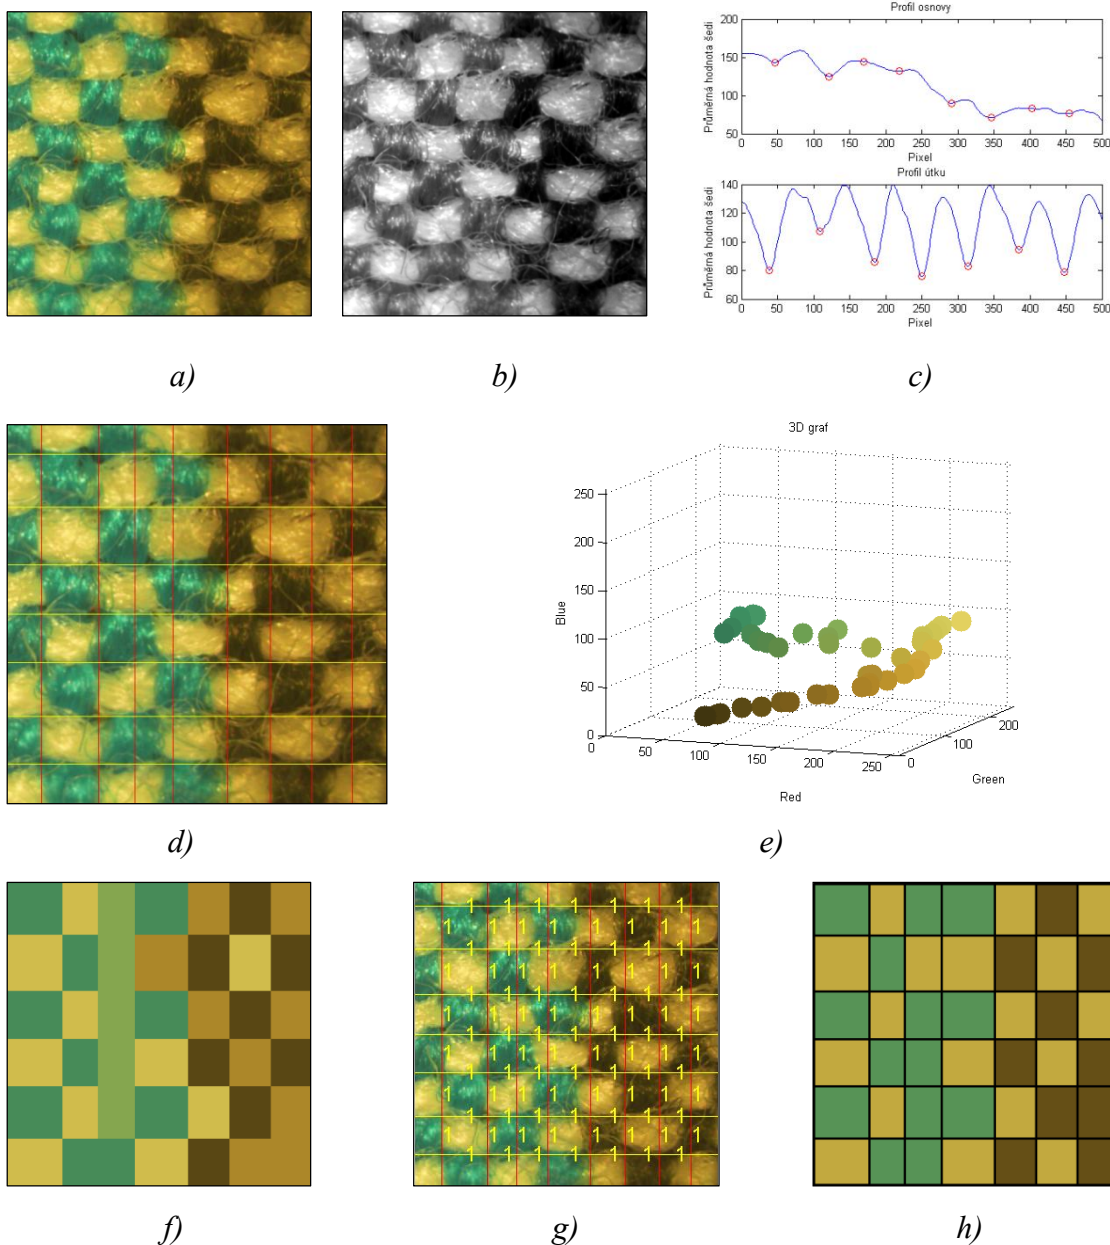


Obr. 38 Čtyřbarevné plátno: a) vstupní obraz RGB, b) šedotónový obraz, c) profil osnoy a útku, d) mříž v tkanině, e) 3D graf, f) tkanina ze dvou barev, g) zjištění hran, h) výsledný obraz tkaniny.

Na obr. 38c) je vidět, že byly dobře identifikovány lokální minima ($filtr = 15$, $okoli = 45$) a tím byly správně odděleny vazné body. Ve 3D grafu na obr. 38e) jsou dobře odseparovány všechny barvy ($vzdalenost = 16$). Na obr. 38g) jsou zapsány indexy pro hledání hran mezi vaznými body ($prechod = 20$, $prah = 8$) a na obr. 38h) jsou zakresleny nalezené hrany z obr. 38g).

Podle výsledného obrazu tkaniny lze říci, že metodu je vhodné použít i na tkaniny plátňové vazby skládající se ze čtyř barev.


5.2.4 Vzorek P8



Obr. 39 Tříbarevné plátno s chybou ve vykreslení profilu: a) vstupní obraz RGB, b) šedotónový obraz, c) profil osnovy a útku, d) mříž v tkanině, e) 3D graf, f) tkanina ze dvou barev, g) zjištění hran, h) výsledný obraz tkaniny.

Na obr. 39a) je zobrazena tříbarevná tkanina skládající se ze dvou rozlišných nití v osnově a jednou nití v útku, která je proložena mříží. Mříž by měla oddělovat jednotlivé vazné body. Všechny horizontální čáry procházejí mezery mezi nitěmi, kdežto vertikální čáry procházejí i skrz vazné body (viz obr. 39d). Na obr. 39h) je zobrazena výsledná tkanina se špatně identifikovanými lokálními minimy ve směru útku.

Na obr. 40 jsou znázorněny stejné profily osnovy a útku jako je na obr. 39c). Třetí a čtvrté lokální minimum by mělo být spojené v jedno. Sedmé a osmé minimum jsou také špatně vykresleny, je to zřejmě způsobeno tím, že se jednotlivé útkové vazné body nad sebou překrývají, tudíž nelze vést jednu přímkou mezi body. Z grafu na obr. 40 nahoře je vidět skok mezi průměrnými hodnotami šedi, profil osnovních nití od cca 280. pixelu klesá z hodnoty 130 na úroveň hodnoty 75. Je to způsobeno různými odstíny šedi odpovídající dané barvě osnovy.

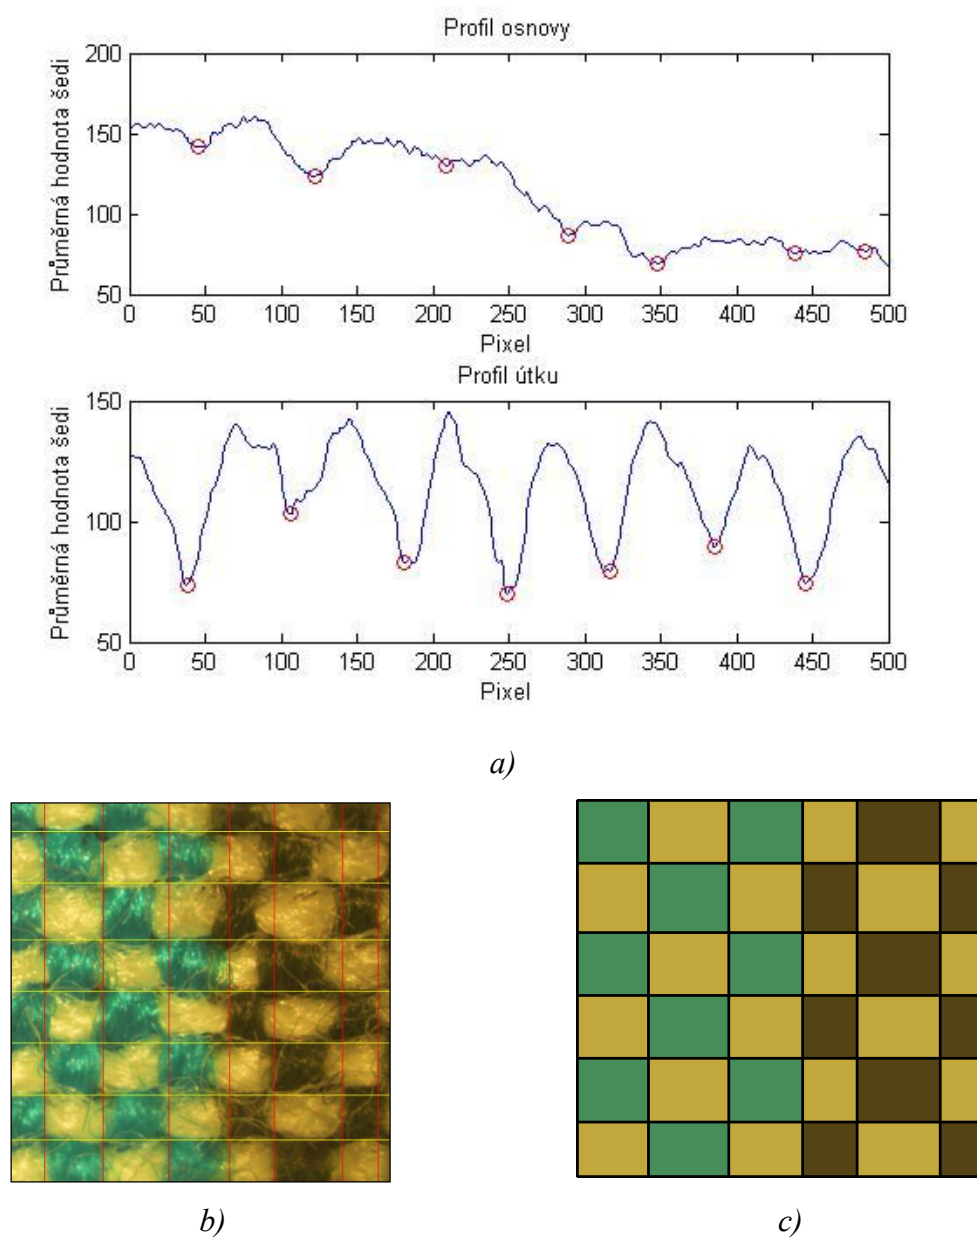


Obr. 40 Profily soustav.

Nepřesné hledání lokálních extrémů je možné odstranit tím, že se změní parametry pro hledání vazných bodů. Původní parametr *filtr* pro vyhlazení funkce klouzavým průměrem ze vztahu (27) byl stanoven na 15 pixelů a velikost parametru *okoli*, který


odděluje lokální minima, byl stanoven na 45 pixelů. Pro nové vykreslení profilu byl parametr *filtr* změněn na 2 pixely a velikost parametru *okoli* zůstal zachován.

Na obr. 41a) jsou zobrazeny profily soustav s použitím pozměněných parametrů. Na horním obrázku je zřetelněji vidět, že průběh funkce není hladký, proto byla nalezena jiná lokální minima než na předcházejícím obrázku. Na obr. 41b) je zobrazena mříž, která odděluje jednotlivé vazné body lépe, než tomu bylo u předcházejícího obr. 39d). Výsledná tkanina na obr. 41c) je velmi podobná původnímu obrazu tkaniny.




Obr. 41 Změna parametrů ve vyhledání profilů soustav: a) průměrné profily soustav, b) vykreslená mříž, c) výsledná tkanina.

Jiné řešení pro lepší odhad profilu šedi a nalezení lokálních minim je použití Gaussova filtru. Při hledání se odečte rozmazané pozadí od originálního obrazu, čímž je docíleno vyrovnaní šedotónových odchylek. Průběh algoritmu je zobrazen na obr. 42.




Obr. 42 Použití Gaussova filtru v algoritmu: a) šedotónový obraz, b) rozmazání pomocí Gaussova filtru, c) odečtení rozmazaného obrazu od šedotónového obrazu, d) ekvalizovaný výsledný obra.




Obr. 43 Profil osnovy a útku po aplikaci Gaussova filtru.

Na obr. 42 jsou zobrazeny profily osnovy a útku po aplikaci Gaussova filtru. Je vidět, že v grafu pro osnovu není skok mezi průměrnými hodnotami šedi. Tím byly lépe nalezeny mezery mezi nitěmi, které jsou zobrazeny na obr. 44. Na obr. 45 je zobrazená výsledná tkanina s nalezenými hranami mezi vaznými body.



Obr. 44 Oddělení vazných bodů mříží.



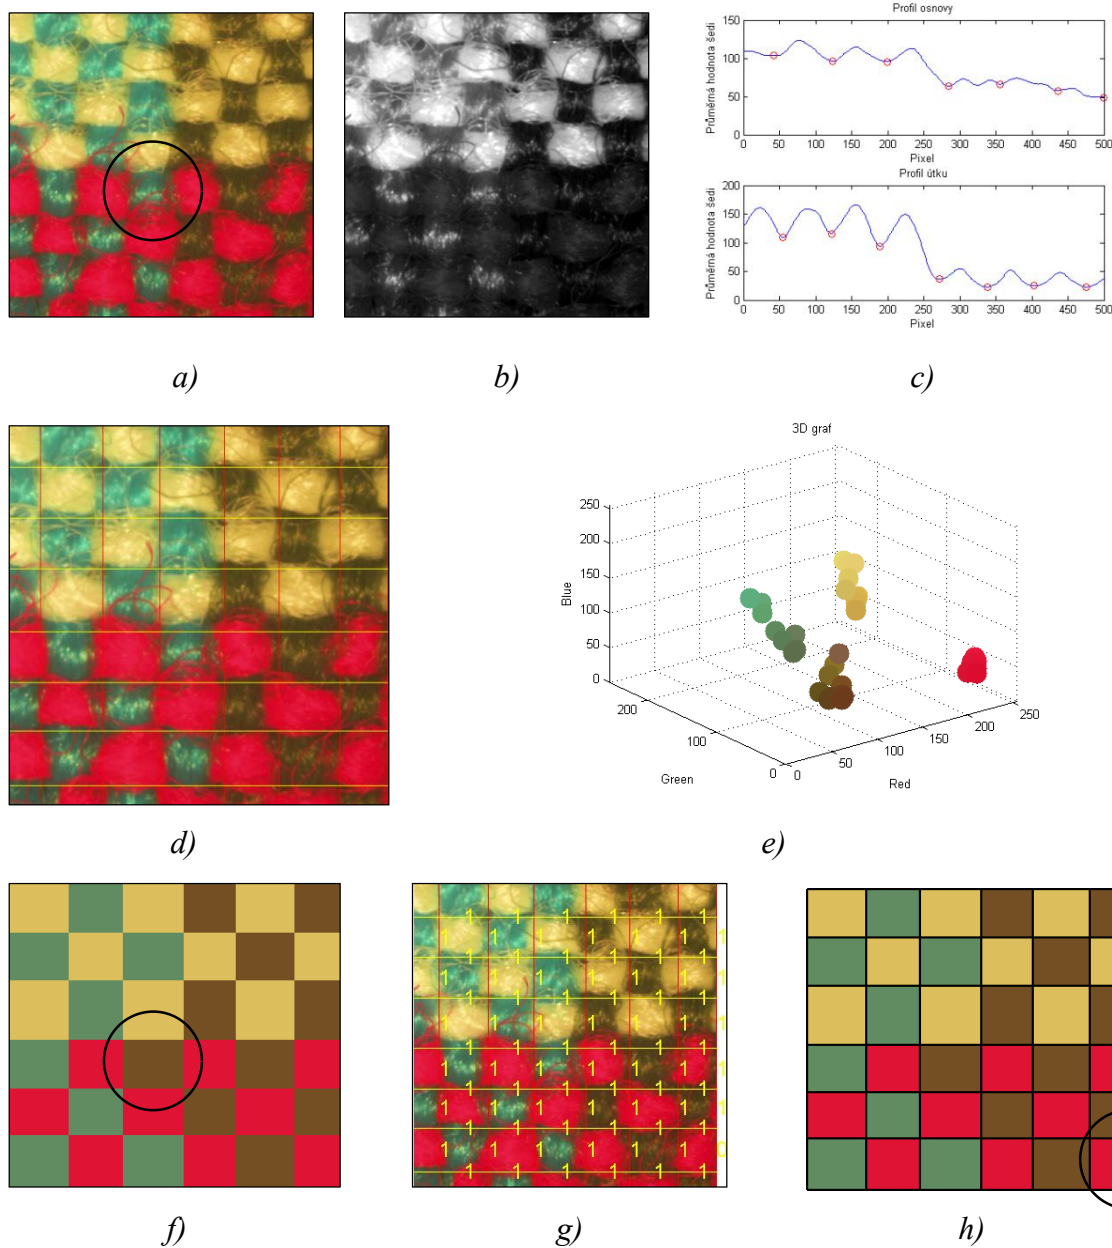
Obr. 45 Výsledný obraz tkaniny.

5.2.5 Vzorek P9


Na obr. 46a) je zobrazena tkanina skládající se ze čtyř barev (dvě barvy v osnově a dvě v útku). Ve 3D grafu na obr. 46e) jsou dobře od sebe odděleny jednotlivé barvy ($filtr = 15$, $okoli = 45$), ale na obr. 46f) je špatně vykreslen jeden vazný bod, znázorněn černým kroužkem. Hrany na obr. 46g) jsou správně identifikovány až na pravou dolní hranu, která je černě zakroužkována ($prechod = 20$, $prah = 8$).

Na obr. 46a) je patrné, že vlákna z okolních vazných bodů zasahují do sledovaného vazného bodu. Do zeleného vazného bodu zasahují červená vlákna z okolních přízí. Shlukovací metodou K-průměrů byly nalezeny čtyři různé barvy, ale sledovanému vaznému bodu byla přiřazena barva hnědá místo zelené.

Chybu lze zřejmě odstranit změnou parametru *vzdalenost* pro výpočet průměrné hodnoty. Původní oblast byla na každé straně zmenšena o 16 pixelů, nyní byla zmenšena o 26 pixelů ($vzdalenost = 28$). Na obr. 47 jsou zobrazeny vybrané operace, aby bylo ukázáno, že po změně parametru pracuje algoritmus správně.




Obr. 46 Čtyřbarevné plátno s chybami: a) vstupní obraz RGB, b) šedotónový obraz, c) profil osnovy a útku, d) mříž v tkanině, e) 3D graf, f) tkanina ze dvou barev, g) zjištění hran, h) výsledný obraz tkaniny.



Obr. 47 Tkanina se změnou parametru: a) vykreslená mříž, b) vykreslení průměrných hodnot oblastí, c) tkanina z nalezeného počtu barev, d) výsledná tkanina.

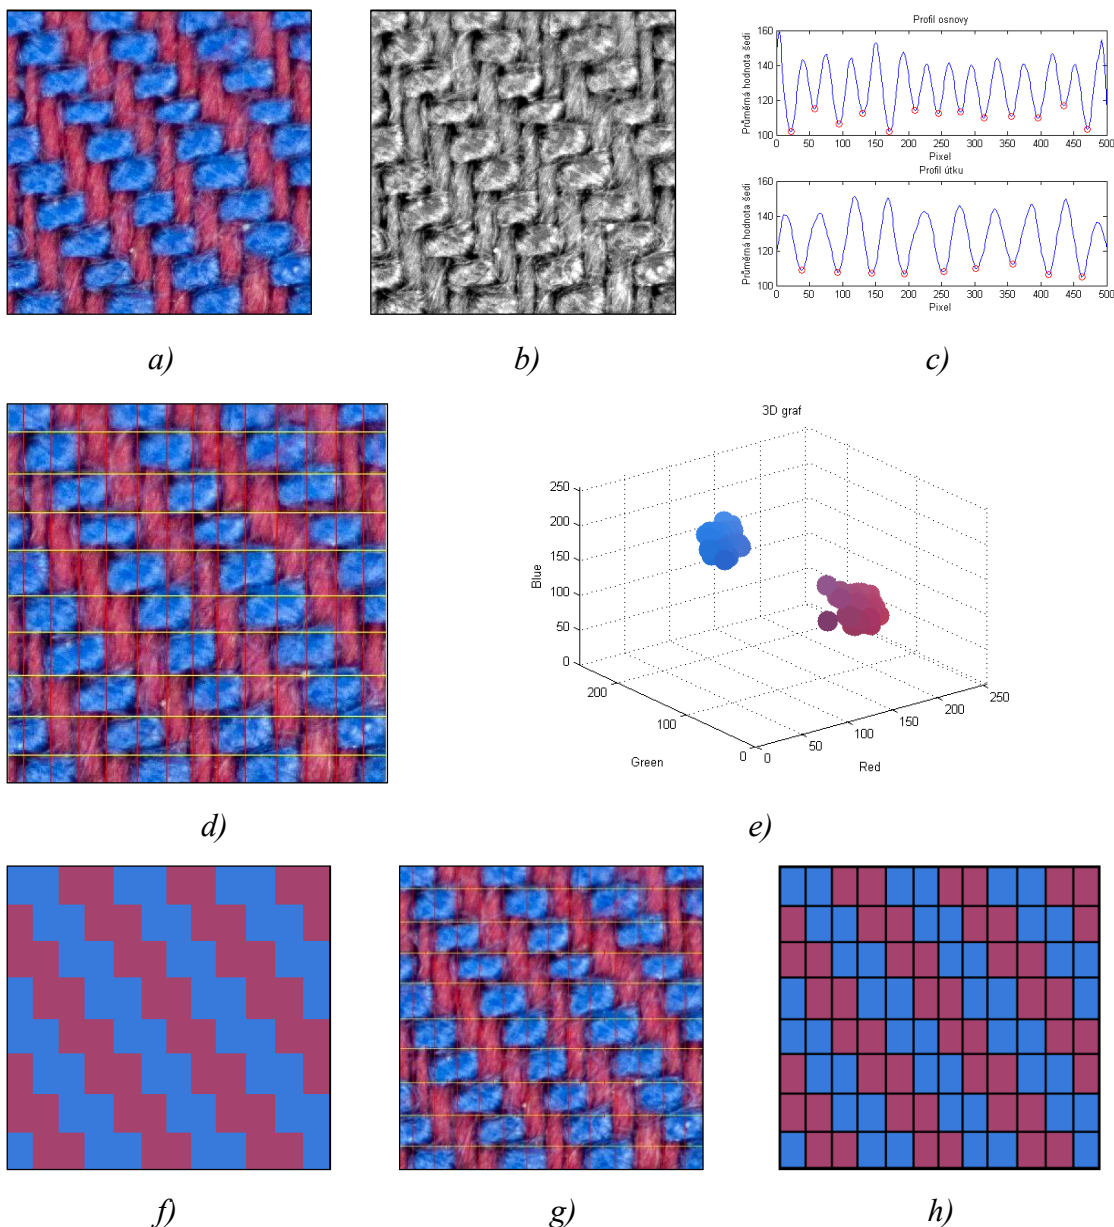
Tímto krokem byla odstraněna špatně vykreslená barva. Další problém, který byl zobrazen kroužkem na obr. 46h), byla špatně vytvořená hrana. Tento defekt je možné odstranit tím, že by byla snížena velikost parametru *prah* pro detekci hrany z 8 na 5 (*prah* = 5). Na obr. 48 je vytvořen výsledný obraz tkaniny již bez žádných chyb.



Obr. 48 Výsledný obraz tkaniny.

Bylo testováno dvanáct dvoubarevných až čtyřbarevných tkanin plátnové vazby. Z toho deset tkanin byly zrekonstruovány správně při prvním aplikaci algoritmu, zbylé dvě až po úpravě parametrů. Proces rekonstrukce je např. ovlivněn nasvícením obrazu při snímání, zešíkmení soustav nití a chlupatostí nití.

5.2.6 Vzorek K1




Obr. 49 Dvoubarevný kepr: a) vstupní obraz RGB, b) šedotónový obraz, c) profil osnovy a útku, d) mříž v tkanině, e) 3D graf, f) tkanina ze dvou barev, g) zjištění hran, h) výsledný obraz tkaniny.

Na obr. 49 je zobrazen průběh algoritmu testován na dvoubarevné keprové tkanině, která má rozlišné barvy v osnově a v útku. V algoritmu byly pozměněny parametry *filtr* a *okoli* pro nalezení vazných bodů, parametr *vzdálenost* pro výpočet průměrné barvy ve vazných bodech a parametr *prechod* pro identifikaci hran mezi vaznými body. Pouze parametr *prah* zůstal zachován.

Z obr. 49 je vidět, že část algoritmu, která slouží ke stanovení hran na základě velikosti směrodatné odchylky pixelů na hraně vazných bodů, není vhodná pro vazby, kde je větší úsek provazujících nití.


Proto byl změněn postup, který se skládá ze dvou částí. Nejprve jsou hranami od sebe odděleny jednotlivé barvy (viz obr. 50), poté se pomocí Houghovy transformace na základě preference směrů vláken ve vazném bodě určí převažující směr nitě.

V první části se vychází z obrazu tkaniny, která obsahuje pouze nalezený počet barev prostřednictvím shlukovací metody K-průměrů, obraz je v barevném modelu RGB. Hraný jsou zjišťovány pouze na přechodu mezi vaznými body, velikost oblasti je $4 \text{ px} \times \text{parametr } prechod$. Princip je založen na porovnání dvou pixelů, vždy je porovnáván jeden pixel ve vazném bodě s jedním pixelem ve druhém vazném bodě. Pokud jsou pixely odlišné, vytvoří se mezi vaznými body hrana.



Obr. 50 Rozdělení barev hranami.

V druhé části byly pomocí Houghovy transformace zjištěny převažující směry vláken ve vazných bodech. Na obr. 51 je zobrazen postup Houghovy transformace pro jeden vazný bod (5. řádek, 4. sloupek) z obr. 49a).




Obr. 51 Aplikace Houghovy transformace na jeden vazný bod: a) vazný bod v barvách RGB, b) vazný bod v odstínech šedi, c) nalezené hrany pomocí hranového operátoru, d) akumulátor.

V této části algoritmu se vychází z šedotónového obrazu po aplikaci Gaussova filtru, který byl pomocí Cannyho hranového operátoru převeden do binárního obrazu. Ve zmenšených vazných bodech, jako tomu bylo při zjišťování průměrné barvy, byly hledány převažující směry vláken. Pro deset bodů, jimiž procházelo nejvíce přímek, byly zjištěny úhly ρ . Z těchto deseti hodnot byl dopočítán medián, který udává výsledný směr vláken pomocí následujícího pravidla

$$\begin{aligned}
 &0 \text{ (osnovní nit) když } |\text{medián}| \leq 15^\circ, \\
 &1 \text{ (útková nit) když } |\text{medián}| > 15^\circ.
 \end{aligned}
 \tag{36}$$

Zákrut nití ovlivňuje výsledný směr vláken ve vazných bodech, proto byla použita velikost úhlu $\theta = 15^\circ$. Aplikací vztahu (30) vznikne matice skládající se pouze z 1 a 0.

Obraz po aplikaci shlukovací metody, prostřednictvím které byl nalezen optimální počet barev ve tkanině, byl zakódován pomocí 1 a 2. 1 značí všechny vazné body nalezené jedné barvy a 2 značí všechny vazné body, které jsou zobrazeny druhou nalezenou barvou. Dále byl sledován směr všech vazných bodů pro každou barvu. Pomocí histogramu o dvou třídách (0 – osnovní směr, 1 – útkový směr) byl stanoven výsledný směr vláken. Poté byla provedena korekce matice skládající se z 1 a 2 (1 – jedna barva, 2 – druhá barva) do matice obsahující 0 a 1 (0 – osnovní směr, 1 – útkový směr). Po korekci byly do obrazu skládajícího se ze dvou barev a obsahující hrany mezi jednotlivými barvami přidány hrany, které oddělují jednotlivé nitě, u osnovních nití byly vytvořeny hrany ve vertikálním směru a u útkových nití byly zobrazeny hrany v horizontálním směru. Na obr. 52 je zobrazen výsledný obraz tkaniny.





Obr. 52 Výsledný obraz tkaniny.

Bylo testováno šest dvoubarevných tkanin keprové vazby, které mají jinou barvu v osnově a v útku. Rekonstrukce vazby proběhla bez chyb u pěti tkanin.

6. VÝSLEDKY REKONSTRUKCE VAZBY TKANINY

V této kapitole jsou zobrazeny obrazy tkanin (viz obr. 53) a jejich výsledné obrazy po rekonstrukci. V původním obrazu tkaniny je zobrazena černým rámečkem velikost zrekonstruovaného obrazu.





Obr. 53 Výsledné obrazy tkanin: a) P1, b) P2, c) P3, d) P4, e) P5, f) P6, g) P7, h) P8, i) P9, j) P10, k) P11, l) P12, m) K1, n) K2, o) K3, p) K4, q) K5, r) K6.

Celkem bylo testováno osmnáct tkanin plátňové a keprové vazby, jejichž použité parametry v algoritmu jsou zapsány v tab. 7. U patnácti tkanin proběhla rekonstrukce bez chyb. U jedné plátňové tkaniny chyběla vykreslená jedna hrana mezi vaznými body a byla špatně identifikována barva jednoho vazného bodu, u druhé plátňové tkaniny byly špatně odděleny vazné body a u jedné keprové tkaniny byl chybně identifikován vazný bod.

Tab. 7 Použité parametry v algoritmu.

Vzorek	Parametry				
	<i>filtr</i>	<i>okoli</i>	<i>vzdalenost</i>	<i>prechod</i>	<i>prah</i>
P1	15	45	16	20	8
P2	15	45	16	20	8
P3	15	45	16	20	8
P4	15	45	16	20	8
P5	15	45	16	20	8
P6	15	45	16	20	8
P7	15	45	16	20	8
P8	15	45	16	20	8
P9	15	45	16	20	8
P10	15	45	16	20	8
P11	15	45	16	20	8
P12	15	45	16	20	8
K1	25	30	10	10	8
K2	25	30	10	10	8
K3	25	30	10	10	8
K4	25	30	10	10	8
K5	25	30	10	10	8
K6	25	30	10	10	8

Jak již bylo zmíněno v předešlém textu, výsledek rekonstrukce tkaniny závisí na několika faktorech, mezi které patří chlupatost nití, zákrut nití, odstávající vlákna ve tkanině, kvalita nasnímaného obrazu tkaniny a zešíkmení soustav nití.

ZÁVĚR

Cílem práce bylo provést rekonstrukci vazby tkaniny prostřednictvím obrazové analýzy vytvořením algoritmem s parametry, který lze aplikovat na co nejširší okruh tkanin. Algoritmus byl použit na obrazy tkaniny plátňové a keprové vazby.

Nejprve byla v grafu průměrných profilů soustav nalezena lokální minima reprezentující mezery mezi nitěmi. Z důvodu velkého počtu lokálních minim byl průběh křivky vyhlazen metodou klouzavých průměrů, pomocí které byl nalezen jejich správný počet. Pro efektivnější vyhledávání lokálních extrémů byl na šedotónový obraz aplikován Gaussův filtr. Při hledání bylo odečteno rozmazané pozadí od originálního obrazu, čímž bylo docíleno vyrovnaní šedotónových odchylek.

V dalším kroku byly zjišťovány barvy vazných bodů v obraze tkaniny. Nejprve byly zjištěny průměrné barvy ve vazných bodech, které byly následně zaneseny do 3D grafu. Pro odhad počtu barev v obraze byla použita metoda K-průměrů.

V posledním kroku byly zjišťovány hrany na přechodu mezi vaznými body. Proces se skládal ze dvou částí. Nejprve byly hranou odděleny vazné body, které mají odlišnou barvu. Dále pomocí Houghovy transformace byly nalezeny převažující směry vláken ve vazných bodech. Poté byla vytvořena vertikální hrana u osnovních vazných bodů a u útkových vazných bodů byla zakreslena horizontální hrana.

V práci se vyskytly problémy, jak při určování průměrné barvy vazného bodu, tak i při identifikaci hran mezi nimi. Výsledná barva byla ovlivněna odstávajícími vlákny ve tkanině a stíny mezi jednotlivými nitěmi vzniklými při snímání tkanin. Komplikace s odstávajícími vlákny se projevila i při aplikaci Houghovy transformace, kde odstávající vlákna ovlivňovala výsledný směr nití. Určování směru nití bylo značně ovlivněno i jejich zákrutem. Rekonstrukce vazby byla ovlivněna i leskem v obraze způsobeným špatným osvětlením při snímání obrazu.

Testováním obrazů bylo zjištěno, že algoritmus lze aplikovat na plátňové tkaniny skládající se alespoň ze dvou barev a dvoubarevné keprové tkaniny. Pro plátňové vazby

je vhodnější použít algoritmus, který při hledání hran mezi vaznými body využívá výpočet směrodatné odchylky pixelů na přechodu mezi jednotlivými body. Při rekonstrukci keprové vazby je vhodnější k nalezení hran použít Houghovu transformaci. Výhledem do budoucna práce je rozšíření funkčnosti algoritmu na všechny typy vazeb tkanin.

LITERATURA

- [1] PING, Z., TAO, Y., YUNLONG, S. a XINXING, T. Research on Computer-Aided Analysis and Reverse Reconstruction for the Weave Pattern of Fabric. *Textile Research Journal* **83**(3), 298-310, 2013.
- [2] ZHENG D., HAN Y. a HU J. A New Method for Classification of Woven Structure for Yarn-Dyed Fabric. *Textile Research Journal* **84**(1), 78-95, 2013.
- [3] JEONG Y. a JANG J. Applying Image Analysis to Automatic Inspection of Fabric Density for Woven Fabric, *Fibers Polym*, **6**(2), 156-161, 2005.
- [4] KANG, J. K., KIM, Ch. H. a OH, K. W. Automatic Recognition of Fabric Weave Patterns by Digital Image Analysis. *Textile Research Journal* **69**(2), 77-83, 1999.
- [5] HUANG, C. C., LIU, S. C. a YU W. H. Woven Fabric Analysis by Image Processing: Part I: Identification of Weave Patterns. *Textile Research Journal* **70**(6), 481-485, 2000.
- [6] KUO, Ch. F. J., SHIS, Ch. Y., HO, Ch. E. a PENG, K. Ch. Application of Computer Vision in the Automatic Identification and Classification of Woven Fabric Weave Patterns. *Textile Research Journal* **80**(20), 2144-2157, 2010.
- [7] PAN, R., GAO, W., LIU, J. a WANG, H. Automatic Detection of the Layout of Color Yarns for Yarn-dyed Fabric via a FCM Algorithm. *Textile Research Journal* **80**(12), 1222-1231, 2010.
- [8] SHINOHARA, T., TAKAYAMA, J. Y., OHYAMA, S. a KOBAYASHI, A. Automatic Weave Daigram Construction from Yarn Positional Data of Woven Fabric. *Textile Research Journal* **78**(9), 745-751, 2008.
- [9] JIHYE, L. a SUNGMIN, K. Analysis of Woven Fabric Structure Using Image Analysis and Artificial Inteligence. *ProQuest Technology Collection* **8**(12), 1062-1068, 2011.
- [10] RURU, P., WEIDONG, G., JIHONG, L., HONGBO, W. a XIAOTING, Z. Automatic Detection of Structure Parameters of Yarn-dyed Fabric. *Textile Research Journal* **80**(17), 1819-1832, 2010.

- [11] KUO, CH. F. J., SHIH, CH. Y. a LEE, J. Y. Automatic Recognition of Fabric Weave Patterns by a Fuzzy C-Means Clustering Method. *Textile Research Journal* **74**(2), 107-111, 2004.
- [12] KUO, CH. F. J., SHIH, CH. Y. a LEE, J. Y. Color and Pattern Analysis of Printed Fabric by an Unsupervised Clustering Method. *Textile Research Journal* **75**(1), 9-12, 2005.
- [13] ZHENG, D., HAN, Y. a HU, J. L. A New Method for Classification of Woven Structure for Yarn-dyed Fabric. *Textile Research Journal* **84**(1): 78-95, 2013.
- [14] RŮŽIČKOVÁ, D. *Oděvní materiály*. Vyd. 1. Liberec: Technická univerzita, Textilní fakulta, 2003, 255 s. ISBN 80-708-3682-2.
- [15] MRAZÍKOVÁ, I. *Vazby tkanin listové: základní, odvozené a složené*. Vyd. 1. Liberec: Technická univerzita, 2002, 185 s. ISBN 80-708-3627-X.
- [16] DOSTALOVÁ, M. A KŘIVÁNKOVÁ M. *Základy textilní a oděvní výroby: tkaniny: učební texty pro bakalářská studia v prezenční i kombinované formě výuky*. Vyd. 3., upr. Liberec: Technická univerzita v Liberci, 2004, 185 s. ISBN 80-708-3831-0.
- [17] PAŘILOVÁ, H. *Textilní zbožíznalství: tkaniny: učební texty pro bakalářská studia v prezenční i kombinované formě výuky*. Vyd. 3. Liberec: Technická univerzita v Liberci, 2005, 96 s. ISBN 80-708-3974-0.
- [18] PAŘILOVÁ, H. *Typologie tkanin - textilní zbožíznalství*. Vyd. 1. Liberec: Technická univerzita v Liberci, 2011, 100 s. ISBN 978-80-7372-674-4.
- [19] HLOCH, S., SODOMKA, L., VALÍČEK, J. A RADVANSKÁ, A. *Struktura, vlastnosti, diagnostika a technologie textilií*. Vyd. 1. Prešov: Vydavatelství Michala Vaška, 2006, 276 s. ISBN 80-807-3668-5.
- [20] Digitální obraz. *E-learning* [online]. 2004 [cit. 2013-09-25]. Dostupné z: http://e-learning.tul.cz/cgi-bin/elearning/elearning.fcgi?ID_tema=67&ID_obsah=1114&stranka=publ_tema&akce=polozka_vstup.
- [21] Digitalizace a zpracování obrazu. *Home.zcu* [online]. 2006 [cit. 2013-09-25]. Dostupné z: <http://home.zcu.cz/~holota5/publ/DigZprO.pdf>.

- [22] Zpracování a analýza obrazu: Základní práce s obrazem. *E-learning* [online]. 2007 [cit. 2013-09-25]. Dostupné z: http://blade1.ft.tul.cz/cgi-bin/elearning/elearning.fcgi?page=publ&action=showThemeContentText&item=489&theme_id=39.
- [23] GONZALEZ, R. C., WOOD, R. E. a EDDINS, S. L. *Digital Image Processing*. 2nd edition, Prentice- Hall, 2002.
- [24] HLAVÁČ, V. A SEDLÁČEK, M. *Zpracování signálů a obrazů*. 2. přeprac. vyd. Praha: ČVUT, 2007, 255 s. ISBN 978-80-01-03110-0.
- [25] HLAVÁČ, V. A ŠONKA, M. *Počítačové vidění*. Praha: Grada. ISBN 80-854-2467-3.
- [26] Počítačová podpora řízení jakosti a analýzy dat. E-learning [online]. 2012 [cit. 2014-01-21]. Dostupné z: https://blade1.ft.tul.cz/elearning/Media/File/5/105/PPJ_3P_03_10_2013.pdf.
- [27] MELOUN, M. A MILITKÝ, J. *Kompéndium statistického zpracování dat: metody a řešené úlohy včetně CD*. Vyd. 1. Praha: Academia, 2002. ISBN 80-200-1008-4.
- [28] *Segmentace obrazu. Práhování. Houghova transformace. Detekce bodů, linií a hran. Rozrůstání oblastí* [online]. Technická univerzita v Liberci [cit. 2014-05-15]. Dostupné z: <https://blade1.ft.tul.cz/elearning/Media/File/5/126/P5.pdf>.
- [29] *Charakteristiky objektů v obraze. Popis tvaru objektů* [online]. Technická univerzita v Liberci [cit. 2014-05-15]. Dostupné z: <https://blade1.ft.tul.cz/elearning/Media/File/5/126/P8.pdf>.

SEZNAM OBRÁZKŮ

Obr. 1	Vstupní obraz (RGB).
Obr. 2	Šedotónový obraz.
Obr. 3	Průměrný profil osnovy a útku.
Obr. 4	Vykreslená lokální minima.
Obr. 5	Vazný bod.
Obr. 6	Vazba tkaniny.
Obr. 7	Typy digitálních obrazů.
Obr. 8	Typy obrazů a jejich histogramy.
Obr. 9	Obrazy a jejich histogramy.
Obr. 10	Zvýšení kontrastu v obraze.
Obr. 11	Průměrovací filtr – velikost 3×3 .
Obr. 12	Prahování obrazu.
Obr. 13	Houghova transformace dle [28].
Obr. 14	Hledání přímek v obraze dle [28].
Obr. 15	Příklady sousednosti dle [29].
Obr. 16	Vzdálenosti mezi pixely.
Obr. 17	Sada vzorků.
Obr. 18	Obraz tkaniny.
Obr. 19	Profil osnovy a útku bez vyhlazení dat.
Obr. 20	Nalezení mezer mezi nitěmi.
Obr. 21	Průměrné profily vyhlazeny klouzavým průměrem (filtr = 15) dle vztahu (27) a (28).
Obr. 22	Lokální minima vyhlazených profilů představující mezery mezi nitěmi.
Obr. 23	Zakreslení nalezených lokálních minim do obrazu RGB.
Obr. 24	Oblast pro výpočet průměrné barvy vazného bodu.
Obr. 25	Vykreslení průměrných barev vazných bodů.
Obr. 26	3D graf.
Obr. 27	Dendrogram.
Obr. 28	Dendrogram s prahem.
Obr. 29	Schéma algoritmu K-průměrů.
Obr. 30	Siluetu pro tři shluky.

Obr. 31	Siluety pro dva shluky.
Obr. 32	Tkanina ze dvou barev.
Obr. 33	Oblast pro výpočet směrodatné odchylky pixelu.
Obr. 34	Zjištění hran.
Obr. 35	Výsledný obraz tkaniny.
Obr. 36	Dvoubarevné plátno.
Obr. 37	Tříbarevné plátno.
Obr. 38	Čtyřbarevné plátno.
Obr. 39	Tříbarevné plátno s chybou ve vykreslení profilu.
Obr. 40	Profily soustav.
Obr. 41	Změna parametrů ve vyhledání profilů soustav.
Obr. 42	Použití Gaussova filtru v algoritmu.
Obr. 43	Profil osnovy a útku po aplikaci Gaussova filtru.
Obr. 44	Oddělení vazných bodů mříží.
Obr. 45	Výsledný obraz tkaniny.
Obr. 46	Čtyřbarevné plátno s chybami.
Obr. 47	Tkanina se změnou parametru.
Obr. 48	Výsledný obraz tkaniny.
Obr. 49	Dvoubarevný kepr.
Obr. 50	Rozdělení barev hranami.
Obr. 51	Aplikace Houghovy transformace na jeden vazný bod.
Obr. 52	Výsledný obraz tkaniny.
Obr. 53	Výsledné obrazy tkanin.

SEZNAM ROVNIC

- | | |
|------|---|
| (1) | Plošná měrná hmotnost |
| (2) | Plošné zakrytí |
| (3) | Setkání osnovy |
| (4) | Setkání útku |
| (5) | Plátňová vazba |
| (6) | Keprova vazba |
| (7) | Atlasova vazba |
| (8) | Reprezentace digitálního obrazu |
| (9) | Počet úrovní jasu |
| (10) | Obrazová funkce pro binární obraz |
| (11) | Obrazová funkce pro šedotónový obraz |
| (12) | Obrazová funkce pro barevný obraz RGB |
| (13) | Normalizace histogramu |
| (14) | Zpracování v prostorové oblasti |
| (15) | Lineární funkce přímky |
| (16) | Lineární prostorová filtrace |
| (17) | Prahování |
| (18) | Víceúrovňové prahování |
| (19) | Vytvoření dvou skupin pixelů u prahování |
| (20) | Nová hodnota globálního prahu |
| (21) | Parametrický tvar rovnice přímky |
| (22) | Normálový tvar rovnice přímky |
| (23) | Euklidovská vzdálenost |
| (24) | Šedotónový obraz z RGB obrazu |
| (25) | Průměrná hodnota šedi ve směru osnovy |
| (26) | Průměrná hodnota šedi ve směru útku |
| (27) | Metoda klouzavých průměrů ve směru osnovy |
| (28) | Metoda klouzavých průměrů ve směru útku |
| (29) | Nalezení lokálních minim ve směru útku |
| (30) | Nalezení lokálních minim ve směru osnovy |
| (31) | Průměrná barva ve vazném bodě |

- (32) Mezishluková suma čtverců
- (33) Míra podobnosti (shlukovací metoda K-průměrů)
- (34) Směrodatná odchylka pixelu na přechodu vazných bodů
- (35) Podmínky pro stanovení hran mezi vaznými body
- (36) Pravidlo pro zjištění převažujícího směru vláken ve vazném bodě

SEZNAM TABULEK

Tab. 1	Popis vzorků tkanin.
Tab. 2	Průměrné barvy vazných bodů z obr. 22.
Tab. 3	Průměrné hodnoty z grafu siluet.
Tab. 4	Průměrné hodnoty z grafu siluet pro tkaninu P4.
Tab. 5	Průměrné hodnoty z grafu siluet pro tkaninu P7.
Tab. 6	Průměrné hodnoty z grafu siluet pro tkaninu P11.
Tab. 7	Použité parametry v algoritmu.

SEZNAM PŘÍLOH

Příloha 1	Algoritmus pro tkaniny plátnové vazby
Příloha 2	Algoritmus pro tkaniny keprové vazby
Příloha 3	Algoritmus pro Houghovu transformaci
Příloha 4	Použité funkce v programu MATLAB

PŘÍLOHA 1

Algoritmus pro tkaniny plátnové vazby

```
clc,clear,close all
```

```
%% Parametry
```

```
filtr=15;  
okoli=45;  
vzdalenost=16; % po K-means (průměr)  
prechod=20; % velikost, o kterou se zmenšuje oblast u hran  
prah=8;
```

```
%% Předzpracování obrazu
```

```
Irgb=imread('9.jpg'); % načtení obrazu  
figure,imshow(Irgb)  
I=rgb2gray(Irgb); % převedení do šedotónového  
figure,imshow(I);  
I=imadjust(I); % vylepšení kontrastu  
Ifin=I;Ifin(:,2)=I;Ifin(:,3)=I;  
figure,imshow(I,[])  
[r s]=size(I); % velikost obrazu
```

```
h = fspecial('gaussian', 50, 50);  
III=imfilter(I,h,'replicate');  
figure,imshow(III,[])
```

```
I=uint8(255*mat2gray(double(I)-double(III)));  
figure,imshow(I,[])  
I=histeq(I);  
figure,imshow(I,[])
```

```
%% Profil soustavy
```

```
O=mean(I);  
O=smooth(O,filtr); % vyhlazení dat pomocí klouzavého průměrovacího filtru o velikosti FILTR  
[pksO,locsO]=findpeaks(-O,'minpeakdistance',okoli); % minus hledá údolí  
% najde vrcholy, které jsou odděleny více než je velikost OKOLI  
% locs...polohy minim v grafu  
vlsO=-pksO; % údolí
```

```
U=mean(I');  
U=smooth(U,filtr);  
[pksU,locsU] = findpeaks(-U,'minpeakdistance',okoli);  
vlsU=-pksU;
```

```
% Zobrazení profilu
```

```
figure  
subplot(2,1,1),plot(O),hold on  
plot(locsO,-pksO,'or') % zakroužkování  
xlabel('Pixel'),ylabel('Průměrná hodnota šedi'),title('Profil osnovy');  
subplot(2,1,2),plot(U),hold on  
plot(locsU,-pksU,'or')  
xlabel('Pixel'),ylabel('Průměrná hodnota šedi'),title('Profil útku');
```

```
figure,imshow(Irgb)  
for i=1:length(locsO)  
    line([locsO(i) locsO(i)],[1 r], 'Color',[1 0 0]) % vytvoření svislých čar  
end  
for j=1:length(locsU)
```

```

line([1 s],[locsU(jj) locsU(jj)],'Color',[1 1 0]) % vytvoření vodorovných čar
end

%% Vykreslení průměrných hodnot z mříže
Ivy=255*ones(size(I));Ivys(:,1)=Ivy;Ivys(:,2)=Ivy;Ivys(:,3)=Ivy;
Ivys1=Ivys;
Igr=zeros(size(I)); % vytvoření nulové matice o velikosti I
IN=zeros(size(I));
cit=1;
pole=[]; % příprava prázdné matice
for ii=1:length(locsO)-1
    for jj=1:length(locsU)-1
        In=Irgb(locsU(jj)+vzdalenost:locsU(jj+1)-vzdalenost,locsO(ii)+vzdalenost:locsO(ii+1)-
vzdalenost,:);
        IGR=I(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1));
        mR=mean(mean(In(:,1)));mG=mean(mean(In(:,2)));mB=mean(mean(In(:,3)));
        meaG=mean(mean(IGR));
        pole=[pole; cit mR mG mB meaG];
        Ivys(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),1)=mR;
        Ivys(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),2)=mG;
        Ivys(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),3)=mB;
        Igr(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1))=meaG;
        cit=cit+1;
    end
end
figure,imshow(uint8(Ivys),[]) % vykreslení v RGB
figure,imshow(uint8(Igr)) % vykreslení v odstínech šedi
pole=double(pole);

%% Barvy
% 3D graf barev poli
figure
for iii=1:length(pole)
    plot3(pole(iii,2),pole(iii,3),pole(iii,4),','MarkerSize',50,'MarkerEdgeColor',[pole(iii,2)/255
pole(iii,3)/255 pole(iii,4)/255],'MarkerFaceColor',[pole(iii,2)/255 pole(iii,3)/255 pole(iii,4)/255]);
    hold on
end
grid on,axis([0 255 0 255 0 255]) % velikost os
xlabel('Red'),ylabel('Green'),zlabel('Blue'),title('3D graf')

%% K means
hod=[];
for k=2:8
    [IDX,C,sumd,D]=kmeans(pole(:,2:4),k);
    [ss]=silhouette(pole(:,2:4),IDX);
    hod=[hod; k mean(ss) mean(sumd)];
end

[IDX,C,sumd,D]=kmeans(pole(:,2:4),hod(find(max(hod(:,2))==hod(:,2)),1));
% nalezení nejvyšší střední hodnoty
cit=1;
for ii=1:length(locsO)-1
    for jj=1:length(locsU)-1
        Ivys1(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),1)=C(IDX(cit),1);
        Ivys1(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),2)=C(IDX(cit),2);
        Ivys1(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),3)=C(IDX(cit),3);
        cit=cit+1;
    end
end
figure,imshow(uint8(Ivys1),[]) % vytvoření vzoru tkaniny pro nalezený počet barev

```

```

Ivys2=Ivys1;
%% Příprava mříže pro hrany
figure,imshow(Irgb)
for i=1:length(locsO)
    line([locsO(i) locsO(i)],[1 r],'Color',[1 0 0]) % vytvoření svislých čar
end
for j=1:length(locsU)
    line([1 s],[locsU(j) locsU(j)],'Color',[1 1 0]) % vytvoření vodorovných čar
end

%% Hrany
hranaO=[];
cit=1;
for i=1:length(locsO)
    for j=1:length(locsU)-1
        lhO=imcrop(I,[locsO(i)-prechod locsU(j) 2*prechod locsU(j+1)-locsU(j)]);
        rlhO=max(max(lhO))-min(min(lhO));
        slhO=std2(lhO);
        if slhO>prah
            text(locsO(i),(locsU(j)+locsU(j+1))/2,'1','Color','r')
            Ivys2(locsU(j):locsU(j+1),locsO(i)-1:locsO(i)+1,:)=0;
        else text(locsO(i),(locsU(j)+locsU(j+1))/2,'0','Color','r')
        end
        % zapsání 0 a 1 do mříže (0=není hrana,1=je hrana)
        %rectangle('Position',[locsO(i)-prechod locsU(j) 2*prechod locsU(j+1)-locsU(j)],'EdgeColor',[1
        0 1]);
        % pomocné čáry (zmenšení oblasti)
        hranaO=[hranaO; cit rlhO slhO];
        cit=cit+1;
    end
end

hranaU=[];
cit=1;
for i=1:length(locsO)-1
    for j=1:length(locsU)
        lhU=imcrop(I,[locsO(i) locsU(j)-prechod locsO(i+1)-locsO(i) 2*prechod]);
        rlhU=max(max(lhU))-min(min(lhU));
        slhU=std2(lhU);
        if slhU>prah
            text((locsO(i)+locsO(i+1))/2,locsU(j),'1','Color','r')
            Ivys2(locsU(j)-1:locsU(j)+1,locsO(i):locsO(i+1),:)=0;
        else text((locsO(i)+locsO(i+1))/2,locsU(j),'0','Color','r')
        end
        %rectangle('Position',[locsO(i) locsU(j)-prechod locsO(i+1)-locsO(i) 2*prechod],'EdgeColor',[0
        1 1]);
        hranaU=[hranaU; cit rlhU slhU];
        cit=cit+1;
    end
end

figure,imshow(uint8(Ivys2),[]) % vytvoření hran v obraze

```

PŘÍLOHA 2

Algoritmus pro tkaniny keprové vazby

```
clc,clear,close all

%% Parametry
filtr=25;
okoli=30;
vzdalenost=10; % po K-means (průměr)
prechod=10; % velikost, o kterou se zmenšuje oblast u hran
prah=8;

%% Předzpracování obrazu
Irgb=imread('K11.jpg'); % načtení obrazu
figure,imshow(Irgb)
I=rgb2gray(Irgb); % převedení do šedotónového
figure,imshow(I);
I=imadjust(I); % vylepšení kontrastu obrazu
Ifin=I;Ifin(:,2)=I;Ifin(:,3)=I;
figure,imshow(I,[])
[r s]=size(I); % velikost obrazu

h = fspecial('gaussian', 50, 50);
III=imfilter(I,h,'replicate');
figure,imshow(III,[])

I=uint8(255*mat2gray(double(I)-double(III)));
figure,imshow(I,[])
I=histeq(I);
figure,imshow(I,[])

%% Profil soustavy
O=mean(I);
O=smooth(O,filtr); % vyhlazení dat pomoci klouzavého průměrovacího filtru o velikosti FILTR
[pksO,locsO]=findpeaks(-O,'minpeakdistance',okoli); % minus hledá údolí
    % najde vrcholy, které jsou odděleny více než je velikost OKOLI
    % locs...polohy minim v grafu
vlsO=-pksO; % údolí

U=mean(I');
U=smooth(U,filtr);
[pksU,locsU] = findpeaks(-U,'minpeakdistance',okoli);
vlsU=-pksU;

% Zobrazení profilu
figure
subplot(2,1,1),plot(O),hold on
plot(locsO,-pksO,'or') % zakroužkování
xlabel('Pixel'),ylabel('Průměrná hodnota šedi'),title('Profil osnovy');
subplot(2,1,2),plot(U),hold on
plot(locsU,-pksU,'or')
xlabel('Pixel'),ylabel('Průměrná hodnota šedi'),title('Profil útku');

figure,imshow(Irgb)
for i=1:length(locsO)
    line([locsO(i) locsO(i)],[1 r],'Color',[1 0 0]) % vytvoření svislých čar
end
for j=1:length(locsU)
```

```

line([1 s],[locsU(j) locsU(j)],'Color',[1 1 0]) % vytvoření vodorovných čar
end

%% Vykreslení průměrných hodnot z mříže
Ivy=255*ones(size(I));Ivys(:,1)=Ivy;Ivys(:,2)=Ivy;Ivys(:,3)=Ivy;
Ivys1=Ivys;
Igr=zeros(size(I)); %vytvoření nulové matice o velikosti I
IN=zeros(size(I));
cit=1;
pole=[]; %příprava prázdné matice
M1=zeros(length(locsU)-1,length(locsO)-1);
for ii=1:length(locsO)-1
    for jj=1:length(locsU)-1
        In=Irgb(locsU(jj)+vzdalenost:locsU(jj+1)-vzdalenost,locsO(ii)+vzdalenost:locsO(ii+1)-
vzdalenost,:);

        %figure,imshow(In)
        %IGR=rgb2gray(In);
        IGR=I(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),:);

        % Hough
        %BW=im2bw(IGR,0.8);
        [BW,threshold] = edge(IGR,'canny');
        %figure,imshow(BW)
        [H,T,R] = hough(BW);
        P = houghpeaks(H,10);
        smery=(T(P(:,2)));
        SM=median(abs(smery));
        if abs(SM)<=15
            Kod=0;
        else Kod=1;
        end
        M1(jj,ii)=Kod;

        mR=mean(mean(In(:,1)));mG=mean(mean(In(:,2)));mB=mean(mean(In(:,3)));
        meaG=mean(mean(IGR));
        pole=[pole; cit mR mG mB meaG SM Kod];
        Ivys(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),1)=mR;
        Ivys(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),2)=mG;
        Ivys(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),3)=mB;
        Igr(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1))=meaG;
        cit=cit+1;
    end
end
figure,imshow(uint8(Ivys),[]) % vykreslení v RGB
figure,imshow(uint8(Igr)) % vykreslení v odstínech šedi
pole=double(pole);

%% Barvy
% 3D graf barev poli
figure
for iii=1:length(pole)
    plot3(pole(iii,2),pole(iii,3),pole(iii,4),'.','MarkerSize',50,'MarkerEdgeColor',[pole(iii,2)/255 pole(iii,3)/255
pole(iii,4)/255],'MarkerFaceColor',[pole(iii,2)/255 pole(iii,3)/255 pole(iii,4)/255]);
    hold on
end
grid on,axis([0 255 0 255 0 255]) % velikost os
xlabel('Red'),ylabel('Green'),zlabel('Blue'),title('3D graf')

%% K means

```

```

hod=[];
for k=2:8
    [IDX,C,sumd,D]=kmeans(pole(:,2:4),k);
    [ss]=silhouette(pole(:,2:4),IDX);
    hod=[hod; k mean(ss) mean(sumd)];
end

[IDX,C,sumd,D]=kmeans(pole(:,2:4),hod(find(max(hod(:,2))==hod(:,2)),1));
% nalezení nejvyšší střední hodnoty
M2=zeros(length(locsU)-1,length(locsO)-1);
cit=1;
for ii=1:length(locsO)-1
    for jj=1:length(locsU)-1
        Ivys1(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),1)=C(IDX(cit),1);
        Ivys1(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),2)=C(IDX(cit),2);
        Ivys1(locsU(jj):locsU(jj+1),locsO(ii):locsO(ii+1),3)=C(IDX(cit),3);
        M2(jj,ii)=IDX(cit);
        cit=cit+1;
    end
end
figure,imshow(uint8(Ivys1),[]) % vytvoření vzoru tkaniny pro nalezený počet barev
Ivys2=Ivys1;

%% Příprava mříže pro hrany
figure,imshow(Irgb)
for i=1:length(locsO)
    line([locsO(i) locsO(i)],[1 r], 'Color',[1 0 0]) % vytvoření svislých čar
end
for j=1:length(locsU)
    line([1 s],[locsU(j) locsU(j)], 'Color',[1 1 0]) % vytvoření vodorovných čar
end

%% Směry
index1=find(M2==1);
n1=hist(M1(index1),2);
pom1=find(n1==max(n1))-1;
index2=find(M2==2);
n2=hist(M1(index2),2);
pom2=find(n2==max(n2))-1;
% korekce
M3=M2;
ind1=find(M2==1);
ind2=find(M2==2);
M3(ind1)=pom1;
M3(ind2)=pom2;

%% Hrany
hranaO=[];
cit=1;
for i=1:length(locsO)
    for j=1:length(locsU)-1
        IhO=imcrop(Ivys1,[locsO(i)-prechod locsU(j)+round((locsU(j+1)-locsU(j))/2)-2 2*prechod 4]); %
        locsU(j+1)-locsU(j)
        % rectangle('Position',[locsO(i)-prechod locsU(j)+round((locsU(j+1)-locsU(j))/2)-2 2*prechod
        4],'EdgeColor',[1 0 1]);
        sIhO=[std2(IhO(:,1)) std2(IhO(:,2)) std2(IhO(:,3))];
        %qO=mean(sIhO);
        pomO=reshape(IhO,size(IhO,1)*size(IhO,2),3);
        qO=median(median(squareform(pdist(double(pomO)))));
        qO1=max(max(squareform(pdist(double(pomO)))));
    end
end

```

```

    if qO1>prah
        text(locsO(i),locsU(j)+round((locsU(j+1)-locsU(j))/2),'1','Color','m')
        Ivys2(locsU(j):locsU(j+1),locsO(i)-1:locsO(i)+1,:)=0;
    else text(locsO(i),locsU(j)+round((locsU(j+1)-locsU(j))/2),'0','Color','m')
    end
    %IhO1=imcrop(I,[locsO(i)-prechod locsU(j)+round((locsU(j+1)-locsU(j))/2)-2*prechod 4]); %
locsU(j+1)-locsU(j)
    cit=cit+1;
end
end

hranaU=[];
cit=1;
for i=1:length(locsO)-1
    for j=1:length(locsU)
        IhU=imcrop(Ivys1,[locsO(i)+round((locsO(i+1)-locsO(i))/2)-2 locsU(j)-prechod 4 2*prechod]); %
locsO(i+1)-locsO(i)
        slhU=[std2(IhU(:,1)) std2(IhU(:,2)) std2(IhU(:,3))];
        pomU=reshape(IhU,size(IhU,1)*size(IhU,2),3);
        qU=median(median(squareform(pdist(double(pomU)))));
        qU1=max(max(squareform(pdist(double(pomU)))));
        if qU1>prah
            text(locsO(i)+round((locsO(i+1)-locsO(i))/2),locsU(j),'1','Color','r')
            Ivys2(locsU(j)-1:locsU(j)+1,locsO(i):locsO(i+1),:)=0;
        else text((locsO(i)+locsO(i+1))/2,locsU(j),'0','Color','r')
        end
        IhU1=imcrop(I,[locsO(i)+round((locsO(i+1)-locsO(i))/2)-2 locsU(j)-prechod 4 2*prechod]); %
locsO(i+1)-locsO(i)
        cit=cit+1;
    end
end
figure,imshow(uint8(Ivys2),[]) % vytvoření hran v obraze

cit=1;
for i=1:length(locsO)-1
    for j=1:length(locsU)-1
        if M3(cit)==0
            Ivys2(locsU(j):locsU(j+1),locsO(i)-1:locsO(i)+1,:)=0;
        else Ivys2(locsU(j)-1:locsU(j)+1,locsO(i):locsO(i+1),:)=0;
        end
        cit=cit+1;
    end
end
figure,imshow(uint8(Ivys2),[]) % vytvoření hran v obraze

```


PŘÍLOHA 3

Algoritmus pro Houghovu transformaci

% Pro vazný bod ve 4. sloupku a na 5. řádku

```
figure,imshow(In) % vazný bod v RGB
figure,imshow(IGR) % vazný bod v odstínech šedi
figure,imshow(BW) % binární vazný bod
[H,T,R] = hough(BW);
P = houghpeaks(H,30);
figure
imshow(H,[],'XData',T,'YData',R,'InitialMagnification','fit');
xlabel('\theta'), ylabel('\rho');
axis on, axis normal, hold on;
plot(T(P(:,2)),R(P(:,1)),'s','color','white');
smery=(T(P(:,2)))
median(smery)
```

PŘÍLOHA 4

Použité funkce v programu MATLAB

abs	absolutní hodnota
axis	délka osy
clc	vyčištění grafického okna
close	zavření grafického okna
edge	nalezení hran v šedotónovém obraze
figure	grafické okno
findpeaks	nalezení lokálního maxima/minima
for ... end	cyklus pro pevný počet opakování
fspecial	vytvoření 2D filtru
gaussian	Gaussův filtr
grid on	mřížka
histeq	ekvalizace histogramu
hold on	podržení grafického okna
hough	Houghova transformace
houhgpeaks	identifikace vrcholů pomocí Houghovy transformace
im2bw	převod šedotónového obrazu na binární obraz
imadjust	zvýšení kontrastu barev v obraze
imcrop	oříznutí obrázku
imfilter	aplikace filtru na obraz
imread	načtení obrazu ze souboru
imshow	zobrazení obrazu
kmeans	shlukování K-průměrů
length	délka
line	vytvoření čar
max	maximální hodnota výběru
mean	vypočítání střední hodnoty z dat (vektor)
mean2	vypočítání střední hodnoty z pole dat
median	vypočítání mediánu z dat
min	minimální hodnota výběru

pdist	vzdálenost mezi dvěma objekty
plot	dvourozměrný graf
plot3	trojrozměrný graf
rectangle	vytvoření 2D obdélníku
reshape	přetvarování matice
rgb2gray	převod barevného obrazu RGB na šedotónový
round	zaokrouhlení na nejbližší celé číslo
silhouette	silueta
size	velikost
smooth	vyhlazení dat pomocí klouzavého průměrovacího filtru s intervalem
std2	vypočítání směrodatné odchylky z dat matice
subplot	vytvoření více grafů do jednoho obrazu
sum	vypočítání sumy
text	vytvoření textu
title	nadpis grafu
xlabel	popis x-ové osy
ylabel	popis y-ové osy
zeros	nulová matice
zlabel	popis z-ové osy